## 明細書

類似率算出装置並びに類似率算出プログラム

### 技術分野

5 本発明は、技術文献群同士を比較して類似性を判断する類似率算出装 置並びに類似率算出プログラムに関する。

# 背景技術

20

25

従来のパテントマップでは、特許文献を用いて、同一又は類似の研究 10 開発テーマの内容について、技術比較を行って、全体的な動向、分布を 知ることが可能であるとされている。そして経営者がパテントマップ見 ることによって、市場動向、技術動向、参入企業及びライバル企業動向 、将来性等の経営判断的要素を分析することが可能とされている。

またパテントマップでは、A社に関連した技術文献A群とB社に関連した技術文献B群とでマクロ的な比較を行う必要がある場合に、技術文献A群と技術文献B群に所属する個々の技術文献どうしをミクロ的に比較し、そこからマクロ的に技術文献群間の比較を導き出していた。

図19は、技術文献A群に含まれる技術文献と、技術文献B群に含まれる技術文献を個々にミクロ的に比較する、従来の比較状況を示す図である。

図19に示すように、技術文献A群に記載されている技術に対し、比較対象の技術文献B群の技術とを比較する場合、従来は、技術文献A群に含まれる技術文献 (特許公報や技報など)と技術文献B群に含まれる技術文献 (特許公報や技報など)を総ての組合せにおいてについて、個々にミクロ的に比較し、これをミクロ的な類似率として数値化し、その平均や分散を求めることにより、2つの技術文献群間の比較数値としていた (例えば、"パテントマップガイダンス"、特許庁、平成14年8月4日検索参照、インターネット<a href="http://www5.ipdl.jpo.go.jp/pmgs1/pmgs1/pmgs">http://www5.ipdl.jpo.go.jp/pmgs1/pmgs/pmgs</a>、以下非特許文献1という。)。

WO 2005/033972 PCT/JP2004/004451

2

特開2000-348015号公報に記載の知的財産評価装置等に は、出願中あるいは登録後の発明等に関する知的財産の財産的価値を評 価する知的財産評価装置において、実施利益に関するデータを入力する 実施利益入力手段と、各年ごとの複利現価率に関するデータを入力する 複利現価率入力手段と、前記実施利益入力手段により入力された各年目 ごとの複利現価率に関するデータとを乗算して、各年目ごとの補償金年 額の複利現価率を算出する複利現価算出手段と、前記複利現価算出手段 により算出された各年ごとの補償金年額の複利現価各年ごとに合算す ることにより知的財産価額を算出する知的財産価格算出手段と、前記知 的財産価格算出手段により算出された知的財産価額を出力する出力手 段とを備えた知的財産評価装置、知的財産評価方法等が記載されている

10

15

20

該知的財産評価装置等では、登録された特許と、それに関連する売上 高や利益などを減価償却して現在残存している特許の資産的価値を把 握しようとするものである。なお、当該発明では、各特許の価値の評価・ は、自社評価や他社評価などをランク付けして入力したものを寄与度と して評価し、具体的な実施権設定がされていない知的財産の資産価値を 算出することが可能であるとされている。

特開2001-76042号公報に記載のシステム等では、所定の更 新間隔を有する第1のデータと更新間隔が当該第1のデータより短い 第2のデータとから、経時的に変動しうる評価項目を評価するシステム であって、(a)サンプル対象の第1のデータの入力に応じて、第1の 評価モデルを作成する手段と、(b)前記サンプル対象の第1のデータ を第1の評価モデルに適用し、第1の評価出力を算出する手段と、(c )サンプル対象の第2のデータと第1の評価出力の入力に応じて、第2 25 の評価モデルを作成する手段と、(d)評価対象の第1のデータの入力 に応じて、当該第1のデータを第1の評価モデルに適用し、第2の評価 出力を算出する手段と、(e)前記評価対象の第2のデータと前記第2· の評価出力を第2の評価モデルに適用し、当該評価対象の評価出力を算

出する手段とを備えた経時的に変動しうる評価対象の評価項目を評価するためのシステム、方法および記録媒体が知られている。

該システムでは、1年単位や四半期単位毎に更新される賃借対照表や 損益計算書等からの財務データ等のように、更新間隔が比較的長い第1 のデータから算出される格付けデータや倒産確率などの企業評価を行 うモデル(静的モデル)と、日々変動する株価や金利、為替等のように 更新間隔が比較的短い第2のデータとの入力に基づき、その後の変化を 予測して動的に企業評価を行うモデル(動的モデル)の2つの評価モデルについて、評価対象の企業データを適用することにより、適時、最新の企業評価を算出することが可能であるとされている。

また、特開平8-287081号公報、特開2001-337992 号公報、特開平10-74205号公報、特開平8-278982号公 報、特開平11-73415号公報、及び特開2001-331527 号公報では、ある文書や文章と類似する内容の文書や文章を検索する際 に、文書や文章同士の類似度や信憑性が高く、高精度に類似文書を検索 することが可能な類似文書検索装置や類似検索システム等が紹介されている。

### 発明の開示

20 ところが、非特許文献1に記載のパテントマップや特開平8-2:8:77 081号公報、特開2001-3:3799-2号公報、特開平10-74 205号公報、特開平8-278982号公報、特開平11-7341 5号公報、及び特開2001-3:31-5-27号公報に記載の発明では 例えば、A社に関連した技術文献A群と、B社に関連した技術文献B群 との間で、技術文献に記載されている内容をマクロ的に比較する要求が、 あったとしても、従来は技術文献A群と技術文献B群に所属する個々の、 技術文献どうしを個々ミクロ的に比較し、その複数の演算結果からマグロ的な技術文献群間の比較を導き出していたため、作業効率が悪いという不具合を生じていた。

25

また、非特許文献1に記載のパテントマップでは、技術比較において、同一又は類似の研究開発テーマの内容ごとに、全体的な動向や分布を知ることが可能であるとされているが、企業間において、企業全体の総技術文献を母集団とした各技術の相対的評価を算出することができないため、無形資産の価値評価手法として、定量的、定性的な結果を得られず、信託や投資の評価の対象、企業の特許戦略の決め手となる技術評価の指標を算出することができないという不具合を生じていた。

また、このミクロ的な類似率を平均する計算方法を用いると、例えば、図19に示す場合において、技術文献群Aと技術文献B群とが全く異なる場合には、類似率は0と算出される。また、全での組合せで求めた平均の類似率も0となるので問題ないように見える。

ところが、第1の技術文献群と第2の技術文献群とがまったく同一の場合であっても、第1の技術文献群に含まれる技術文献A1に対して第2の技術文献群に含まれる技術文献献B1,B2,B3,B4のミクロ的な類似率を求めると、2つの技術文献が全く同一の場合(A1=B1など)にはA1とB1との類似率は1と算出されるが、それ以外の場合には一般に類似率が1になることはない。更にA1以外の、A2、A3、A4などに対する総ての組合せで求めた平均類似率は、1とそれ以下の数値の平均となるので、やはり類似率が1と算出されることはないという不具合を生じる。

20 また、技術文献の総数が数万件以上となる場合のように、多量の技術文献どうしについて類似率を算出する際には、全ての技術文献の組合せたいて類似率を計算する必要があるので、類似率を算出するにあたっての計算量が膨大となるために、計算時間が多く必要となり、類似率の計算結果を素早く表示することができないという不具合を生じている。

また従来のように類似率を算出するにあたり、調査対象と母集団の技術文献をキーワードで切り分け、個々のキーワードが含まれる技術文献の数量と、技術文献の総数との比率を演算し、キーワード総でについて、演算した比率を平均して類似率を算出する方法では、キーワードの重要で性に応じた重み付けを行なわないと、算出される類似率と実際の感覚的

な類似率との差が大きく開いてしまうという不具合を生じている。

この重み付けをしたキーワードを用いて類似率を算出する際に、全キーワードについてオペレータが重み付けを行なってシソーラス辞書を作成し、その重み付けに基づいて類似率を算出することが可能である。これは理論的に可能ではあるが、実際に膨大な量のキーワードのそれぞれに重みを付けることは結構大変な作業(至難の業)であるし、処理の自動化にはそぐわない。また、個々の技術文献毎に類似率が算出されることには変わりないので、結局は技術文献同士をミクロ的に比較しているにすぎないという不具合を生じていた。

10 また、非特許文献1に記載のパラントマップでは、パテントマップ作成支援ソフトの価格が、約15万~50万円程度であり、その操作には、コンピュータだけでなく特許請求の範囲、図面等を読み取る等高度な技術力と知識力を必要とする。特許調査機関で依頼する場合でも、1件あたり30万円以上の費用が必要であるとともに、約1ヶ月以上作成時間が必要となる。

従って、資本金や開発費の少ないベンチャー企業等が利用する場合、 あるいは出願を急ぐ場合には、パテントマップの利用が制限されること が想定される。

また、従来の知的財産評価装置等では、製品等の研究開発の着手前に 20 過去から最近の情報を広く収集して、競合他社の技術動向の分析や、技 術レベルを把握する技術動向調査等の調査を行いにくいという不具合 を生じていた。

近年、企業価値に占める無形資産 (インタンジブル・アセット) の割っ合が大きくなるにつれ、無形資産の価値が企業価値を大きく左右するようになってきた。

従って、信託会社は信託の対象に、投資家は投資の対象に、企業は知的財産から産出される利益を重視すべく特許戦略の動向の対象に、それぞれ無形財産を指標として用いる傾向にある。

しかし従来は、投資の参考にするために、技術文献一般を用いて企業

• :

の保有する無形財産を比較するための適切な指標が存在していなかった。

特に、生き残りをかけた企業経営において、新規事業参入や新製品の 開発に着手する前段階において開発費を充てる価値のある技術分野な のか、特許出願すべき価値があるのか、出願審査の請求をすべきか否か 、権利化の可能性があるのか、ライセンス交渉をした場合の方が利益率 が高いか否か等の特許戦略を検討するための指標の存在が、非常に重要 となってきている。

そこで本発明は、上記従来の状況に鑑み、企業間において、特許公報 9に限られない広範な技術文献群同士を比較し、人の感覚と一致する適 当な類似率を算出することによって、定量的、定性的かつ相対的な無形 資産の価値を評価することが可能な指標を算出するための類似率算出 装置、類似率算出プログラム並びに類似率算出方法を提供することを目 的としている。

15 また本発明は、第1の技術文献群と第2の技術文献群とが全く違ったときだけは類似率が0と算出されるとともに、第1の技術文献群と第2の技術文献群とが同一のときだけは類似率が1と算出されうるものであって、大量で時間のかかる計算を必要とせず、分析者の恣意が混入することによって算出される類似率の値が変わる可能性が少なく、第1の20 技術文献群と第2の技術文献群との間でマクロ的な類似性の比較結果を算出することが可能な類似率算出装置、類似率算出プログラム並びに類似率算出方法を提供することを目的としている。

また本発明では、比較する技術文献の総数が数万件以上となる場合であっても、比較的短い計算時間で類似率を算出することが可能な類似率算出装置、類似率算出プログラム並びに類似率算出方法を提供することを目的としている。

また本発明では、技術文献群同士をマクロ的に比較することが可能な類似率算出装置、類似率算出プログラム並びに類似率算出方法を提供することを目的としている。

WO 2005/033972 PCT/JP2004/004451

7

また本発明では、無体財産により企業価値を見極める要求のある投資家等や一般の実務者にも容易に扱うことが可能な類似率算出装置、類似率算出プログラム並びに類似率算出方法を提供することを目的としている。

上記課題を解決するために本発明は、特許文献又は技報等の技術文献から構成される第1の技術文献群と第2の技術文献群との技術的な類似性を判断するための指標を算出する類似率算出装置であって、比較対象となる第1の技術文献群及び第2の技術文献群を入力する技術文献群入力手段と、キーワードやIPCなどの技術情報を入力する技術情報入力手段と、第1の技術文献群及び第2の技術文献を検索して該検索した技術文献をそれぞれの技術情報を含む技術文献を検索して該検索した技術文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数との比を類似率として算出する類似率算出手段と、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する出力手段とを備えたことを特徴とする。

また上記課題を解決するために本発明は、比較対象となる第1の技術 文献群及び第2の技術文献群を入力する技術文献群入力手段と、キーワードやIPCなどの技術情報を入力する技術情報入力手段と、第1の技 術文献群及び第2の技術文献群に含まれる技術文献について前記入力 した技術情報を含む技術文献を検索して該検索した技術文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ 分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技 術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、 各混在クラスタに含まれる技術文献の量に応じた値を取る第1の補正 値と各混在クラスタに含まれる第1の技術文献群の技術文献と第2の 技術文献群の技術文献との混ざり具合に応じた値を取る第2の補正値 とを乗算したものを各混在クラスタについて総和を算出し、前記算出し

. 20

25

た全クラスタ数で除算して類似率を算出する類似率算出手段と、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する出力手段とを備えたことを特徴とする。

また上記課題を解決するために本発明は、比較対象となる第1の技術 文献群及び第2の技術文献群を入力する技術文献群入力手段と、キーワードやIPCなどの技術情報を入力する技術情報入力手段と、第1の技術文献群及び第2の技術文献群に含まれる技術文献について前記入力した技術情報を含む技術文献を検索して該検索した技術文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ 10 分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともでは個々のクラスタ内の技術文献数の企業(但し、〇〜企)に比例した補正値を各混在クラスタについて総和を算出し、全クラスタ数で除算して類似率を算出する類似率算出手段と、前記算出した類似率を記録手段、表記手段、又は通信手段に出力する出力手段とを備えたことを特徴とする。

また上記課題を解決するために本発明は、比較対象となる第1の技術文献群及び第2の技術文献群を入力する技術文献群入力手段と、キーワードやIPCなどの技術情報を入力する技術情報入力手段と、第1の技術文献群及び第2の技術文献群に含まれる技術文献について前記入力、した技術情報を含む技術文献を検索して技術文献をそれぞこれの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、個々のクラスタ内の技術文献数の 

本集(但し、0~な)を、全クラスタク内の技術文献数の 

本集(但し、0~な)を、全クラスタクトの技術文献数の平均値等の規格化因子で除算した補正値を各混在クラスタについて総和を算出し、全クラスタ数で除算して類似率を算出する類似率算出手段と、前記算出した類似率を記録手段、表示手段、又は、通信手段に出力する出力手段とを備えたことを特徴とする。

20

25

WO 2005/033972 PCT/JP2004/004451

9

また上記課題を解決するために本発明は、比較対象となる第1の技術: 文献群及び第2の技術文献群を入力する技術文献群入力手段と、キーワー ードやIPCなどの技術情報を入力する技術情報入力手段と、第1の技 術文献群及び第2の技術文献群に含まれる技術文献について前記入力。 した技術情報を含む技術文献を検索して該検索した技術文献をそれぞ れの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ-分解した結果得られた全クラスタ数と第11の技術文献群及び第2の技 術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、 前記クラスタ分解した結果得られた混在クラスタに含まれる第1の技・ 術文献群及び第2の技術文献群の技術文献数の確率に応じて補正する ために、第1の技術文献群の中からm個に第2の技術文献群の中からn‐ 個の技術文献を取り出す確率のγ乗(但し、0 <γ)に比例した補正値 を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で 除算して類似率を算出する類似率算出手段と、前記算出した類似率を記 録手段、表示手段、又は通信手段に出力する出力手段とを備えたことを 特徴とする。

5

10

15

20

また上記課題を解決するために本発明は、比較対象となる第1の技術 文献群及び第2の技術文献群を入力する技術文献群入力手段と、キャワ ードやIPCなどの技術情報を入力する技術情報入力手段と、第1の技 術文献群及び第2の技術文献群に含まれる技術文献について前記入力 した技術情報を含む技術文献を検索して該検索した技術文献をそれぞ れの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ 分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技 術文献群の双方の技術文献を含む混在グラスタ数を算出するとともに、 25 前記クラスタ分解した結果得られた混在クラスタに含まれる第1の技 術文献群及び第2の技術文献群の技術文献数の確率に応じて補正する ために、第1の技術文献群の中からm個、第2の技術文献群の中からm 個の技術文献を取り出す確率のγ乗記(但起、0×xy)を規格化因子で除 算した補正値を各混在クラスタについで総和を算出し、前記算出した全。 WO 2005/033972 PCT/JP2004/004451

10

クラスタ数で除算して類似率を算出する類似率算出手段と、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する出力手段とを 備えたことを特徴とする。また本発明は、前記規格化因子を、第1の技術文献群の中からm個、第2の技術文献群の中からn個の技術文献を取り出す確率の最大値のγ乗(但し、0 < γ)としたことを特徴としている。

また上記課題を解決するために本発明は、比較対象となる第1の技術 文献群及び第2の技術文献群を入力する技術文献群入力手段と、キーワー ードやIPCなどの技術情報を入力する技術情報入力手段と《第1の技》 術文献群及び第2の技術文献群に含まれる技術文献について。前記入力 した技術情報を含む技術文献を検索して、「該検索した技術文献をそれぞ」 れの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ。 分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技 術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、 第1の技術文献群に含まれる技術文献数Mと第2の技術文献群に含ま れる技術文献数Nとの構成比、N/Mと、前記クラスタ分解した結果得 られた混在クラスタに含まれる第1の技術文献群の技術文献数mと第一 2の技術文献群の技術文献数nの混在比。n/mとについて、更に構成。 比と混在比との比を取ったもののな乗(但し、0~な)に比例した補正。 値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数・ で除算して類似率を算出する類似率算出手段と、前記算出した類似率を 記録手段、表示手段、又は通信手段に出力する出力手段とを備えたこと。 を特徴とする。

10

20

また上記課題を解決するために本発明は、比較対象となる第1の技術 25 文献群及び第2の技術文献群を入力する技術文献群入力手段と、キーワードやIPCなどの技術情報を入力する技術情報入力手段と、第1の技 術文献群及び第2の技術文献群に含まれる技術文献につかで前記入力 した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞ れの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ 分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、第1の技術文献群と第2の技術文献群とを混合した技術文献群の中から、第1の技術文献群の技術文献を取り出す確率に、前記クラスタ分解した混在クラスタに含まれる技術文献数を乗算して第1の技術文献群の技術文献群の技術文献数との差を期待値を混合クラスタに含まれる第1の技術文献群の技術文献数との差を期待値差として算出し、その期待値差を任意定数を(但し、1 くを)の負の指数とした補正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する類似率算出手段と、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する出力手段とを備えたことを特徴とする。

10

また上記課題を解決するために本発明は、比較対象となる第1の技術。 文献群及び第2の技術文献群を入力する技術文献群入力手段と、キーワー ードやIPCなどの技術情報を入力する技術情報入力手段と、第1の技 術文献群及び第2の技術文献群に含まれる技術文献について前記入力 した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞ れの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ 分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技 術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、 20 第1の技術文献群と第2の技術文献群とを混合した技術文献群の中か ら、第1の技術文献群の技術文献を取り出す確率に、前記クラスタ分解 した混在クラスタに含まれる技術文献数を乗算して第1の技術文献群 の技術文献を取り出す期待値を算出し、前記期待値と混合クラスタに含 まれる第1の技術文献群の技術文献数との差を期待値差として算出し、 25 その期待値差を混在クラスタに含まれる技術文献数で除算したものを 任意定数 ξ (但し、1 < ξ) の負の指数とした補正値とし、これを各混 在クラスタについて総和を算出し、更に前記算出した全クラスタ数で除 算して類似率を算出する類似率算出手段と、前記算出した類似率を記録

WO 2005/033972 PCT/JP2004/004451

12

手段、表示手段、又は通信手段に出力する出力手段とを備えたことを特 徴とする。

本発明によれば、特許文献又は技報等の技術文献から構成される第1 の技術文献群と第2の技術文献群との技術的な類似性を判断するため、 の指標を算出する類似率算出装置であって、比較対象となる第1の技術。 文献群及び第2の技術文献群を入力する技術文献群入力手段と、キーワ ードやIPCなどの技術情報を入力する技術情報入力手段と、第1.の技 術文献群及び第2の技術文献群に含まれる技術文献について前記入力: した技術情報を含む技術文献を検索して該検索した技術文献をそれぞ れの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ 10 分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技 術文献群の双方の技術文献を含む混在クラスタ数との比を類似率とし て算出する類似率算出手段と、前記算出した類似率を記録手段、表示手 段、又は通信手段に出力する出力手段とを備えたので、その分解した全 15 - クラスタ数と混在クラスタ数の比に基づいて、技術文献群に記載されて。 いる技術内容の類似性を示す指標を簡便に算出することが可能となる。

また本発明によれば、類似率算出手段に各混在クラスタに含まれる技術文献の量に応じた値を取る第1の補正値と、各混在クラスタに含まれる第1の技術文献群の技術文献と第2の技術文献群の技術文献との混ざり具合に応じた値を取る第2の補正値とを乗算したものを、各混在クラスタについて総和を算出して、全クラスタ数で除算して類似率を算出する機能を設けたので、補正項1の存在により混在クラスタに含まれる技術文献の量に応じて重要度が高いことを意味付ける補正が可能となるとともに、補正項2の存在により混在クラスタに含まれる技術文献の割合が所定の量に近い程、重要なクラスタであるとして、類似率が高い値を示すように重い重み付けをして、類似率の算出結果を、より人の感覚に合うように補正することが可能となる。

20

25

従って、補正項1及び補正項2を用いて類似率を算出することによって、技術文献数量の多い混在クラスタを重要視して類似率を補正すると

20

25

ともに、技術文献の混ざり具合が不均一な場合には、類似率を小さい値で に補正することが可能となる。

また本発明によれば、類似率算出手段に個々のクラスタ内の技術文献 数の α 乗 (但し、0 < α) に比例した補正値を各混在クラスタについて 総和を算出し、全クラスタ数で除算して類似率を算出する機能を設けた。 ので、クラスタ内の技術文献数が多いほど重要なクラスタであるとする。 ような類似率を算出することが可能となる。

また本発明によれば、類似率算出手段に個々のクラスタ内の技術文献数のα乗(但し、0 < α)を、全クラスタ数等の規格化因子で除算して10 類似率を算出する機能を備えたので、0 ≤類似率≤1 を保証することが可能となる。また、規格化因子として全クラスタ内の技術文献数の平均値を基準として技術文献の量の多少を算出することが可能となる。

また本発明によれば類似率算出手段に、第1の技術文献群の中から加個、第2の技術文献群の中から n 個の技術文献を取り出す確率の y 乗 (但し、0 < y) に比例した補正値を各混在クラスタについて総和を算出し、全クラスタ数で除算して類似率を算出する機能を設けた。すなわち、類似率算出手段に(A群の中から m 個、B 群の中から n 個の技術文献を取り出す組合せの数)/(A 群とB 群とを混ぜ合わせた中から m 十 n 個の技術文献を取り出す組合せ数)を分子に配置した演算を行なう機能を備えたので、混在クラスタに含まれる A 群及び B 群の技術文献数の偏り(作為性)に応じて、偏り大の場合は小さい補正値に、偏り小の場合は大きい補正値に類似率を補正することが可能となる。また、規格化因子として、第1の技術文献群の中から m 個の技術文献を取り出す確率の最大値の y 乗 (但し、0 < y) を配置したので、類似率の算出範囲として 0 ≤ 類似率 ≤ 1 を保証することが可能となる。

また本発明によれば類似率算出手段に、第1の技術文献群に含まれる-技術文献数Mと第2の技術文献群に含まれる技術文献数Nとの構成比。 N/Mと、クラスタ分解した結果得られた混在グラスタに含まれる第1 の技術文献群の技術文献数mと第2の技術文献群の技術文献数nの混 在比、n/mとについて、更に構成比と混在比との比を取ったもののよ 乗(但し、0<よ)に比例した補正値を各混在クラスタについて総和を 算出し、全クラスタ数で除算して類似率を算出する機能を備えたので、 A群とB群の技術文献数量の構成比と各クラスタ内における技術文献 同士の混在比が同じであるほど類似率を高く算出する(1に近づける)。 ことが可能となる。

5

また、構成比と混在比との比の指数をを く>1 に設定することに 10 よって、A群とB群の技術文献数量の比と、各クラスタ内における技術 文献同士の混在比との比が小さい混在クラスタの影響を、類似率の算出 結果に大きく反映させないようにすることが可能となる。

また、指数くを く=1 に設定することによって、単純にA群とB 群の技術文献数量の構成比と、各グラスタ内における技術文献同士の混 在比との比に応じて類似率を増減させることが可能となる。

また、分子の指数を 0 < ζ < 1 に設定することによって、A群と B 群の技術文献数量の構成比と、各クラスタ内における技術文献同士の混在比との比が大きい場合に類似率の算出結果に対する影響を少なくすることが可能となる。

20 また本発明によれば類似率算出手段に、第1の技術文献群と第2の技術文献群とを混合した技術文献群の中から第1の技術文献群の技術文献群の技術文献群の技術文献を取り出す確率に前記クラスタ分解した混在ケラスタに含まれる技術文献数を乗算して第1の技術文献群の技術文献を取り出す期待値を算出し、前記期待値と混合クラスタに含まれる第1の技術文献群の技術文献数との差を期待値差として算出し、その期待値差を任意定数を(但し、1<ξ)の負の指数とした補正値を、各混在クラスタについて総和を算出し、全クラスタ数で除算して類似率と算出するようにしたので、よの値の設定に応じて期待値差に対する類似率の算出結果を敏感に反応させる補正を行なうことが可能となる。

また本発明によれば類似率算出手段に、第1の技術文献群と第2の技術文献群とを混合した技術文献群の中から第1の技術文献群の技術文献群の技術文献群の技術文献を取り出す期待値をです。 第1の技術文献を取り出す期待値をです。 第1の技術文献を取り出す期待値をです。 第1の技術文献群の技術文献を取り出す期待値をです。 第1の技術文献群の技術文献数との差を期待値差として算出し、その期待値差を混在クラスタに含まれる技術文献数で除算したものを、任意定数を(但し、1 < ま)の負の指数とした補正値とし、これを各混在クラスタについて総和を算出し、更に全クラスタ数で除算して類似率と算出するようにしたので、ままの値の設定に応じて期待値差に対する類似率の算出結果を敏感に反応させる補正を行なうことが可能となる。

# 図面の簡単な説明

図1は、本発明に係る類似率算出システムの全体構成図である。

15 図2は、本発明に係る類似率算出装置のプロック図である。

図3は、技術文献A群と技術文献B群に含まれる技術文献の構成を示す。 図である。

図4は、類似率の表示処理を示すフローチャートである。

図5は、類似率算出のための入力画面の表示例を示す図である。

20 図 6 は、算出した類似率を利用者に通知する類似率表示画面の表示例を示す図である。

図7は、本発明に係る類似率算出装置を用いて技術文献群をクラスタ分 解した後の各クラスタの構成を示す図である。

図8は、類似率の算出処理を示すフローチャートである。。

25 図9は、類似率の計算に用いる設定条件を示す図表である。

図10は、混在クラスタ1には技術文献が多く含まれている状況を表す。 図である。

図11は、補正項1(1)を採用した場合の類似率算出例の図表である。

図12は、補正項2(1)を採用した場合の類似率算出例の図表である。

図13は、補正項1(1)及び補正項2((1))の双方を採用した場合の 類似率算出例の図表である。

図14は、補正項2(2)を採用した場合の類似率算出例の図表である。 図15は、補正項1(1)及び補正項2(2)を採用した場合の類似率 算出例の図表である。

図16は、(式31)に条件1~4を代入した場合の期待値差の算出例を示す図表である。

図17は、 $\xi = 10$ とした場合において、(式3-2) に条件 $1 \sim 4$ を依 入した場合の類似率算出例の図表である。

10 図18は、補正項1(1)及び補正項2(3)を採用した場合の類似率 算出例の図表である。

図19は、技術文献A群に含まれる技術文献と、技術文献B群に含まれる技術文献を個々にミクロ的に比較する従来の状況を示す図である。

15 発明を実施するための最良の形態

20

25

図1は、本発明に係る類似率算出システムの全体構成図である。

同図に示すように、本発明に係る類似率算出システムは、技術文献データベース20から通信網10を介して、類似率の算出に必要な技術文献を読み出して、類似率を算出して表示する類似率算出装置3.0と、通信網10を介して各社の技報や、出願済みの特許公報、実用新案公報等の特許文献を含む技術文献を記録する技術文献データベース20とが設けられている。

通信網10は、インターネット等の通信網であって、類似率算出装置 30が通信網10を介して技術文献データベース20から特許文献等 の技術文献に関する情報を取得することが可能となっている。

類似率算出装置30は、利用者から比較対象の技術文献群に関する情報や、文献どうしの比較条件を入力し、技術文献データベース20から通信網10を介して、類似率の算出に必要な技術文献を読み出して、類似率を算出して表示することが可能となっている。

WO 2005/033972 PCT/JP2004/004451

17

図2は、本発明に係る類似率算出装置のブロック図である。

同図に示すように類似率算出装置3-0の情報送受信部には、公衆回線 又は通信ネットワーク等の通信網364を介して、技術文献データベー」 ス20等の他の通信機器と情報の送受信を行なうことが可能な送受信 手段365 (技術文献群入力手段、技術情報入力手段、又は出力手段の 機能を含むものであってもよい)が設けられている。

送受信手段365は、技術文献データベニス20から通信網10を介 して、類似率の算出に必要な技術文献を取得することが可能となってい ゙る。

10 また類似率算出装置30には、利用者から比較対象の技術文献群に関 する情報や、文献同士の比較条件を入力するキーボード、マウス等の入 力手段370(技術情報入力手段の機能を含むものであってもよい)が・ 設けられている。

また類似率算出装置30には、入力手段370を介して入力した各種 15 情報を読み取って後述する情報処理手段3.80に伝達したり、情報処理 手段380からの指示に基づいてLED等に表示指令を出力する入力 インターフェース371(技術情報入力手段の機能を含むものであって もよい)と、画像や文字等の情報を表示する表示手段372(出力手段) の機能を含むものであってもよい)と、情報処理手段38-0の指令に基 づいて表示手段372に対して表示用の画像信号を出力する表示イン ターフェース373 (出力手段の機能を含むものであってもよい)とが、 設けられている。なお、入力手段370は、キーボードやマウスに限ら ず、タブレット等の入力装置を含むものである。

20

また類似率算出装置30には、記録媒体377を着脱可能に装着する 記録媒体装着部378と、記録媒体377に対して各種情報を記録した。 25 り読み出したりする記録媒体インターフェース 3 7 9 (技術文献群入力) 手段、技術情報入力手段、又は出力手段の機能を含むものであってもよ い)とが設けられている。なお、記録媒体377は、メモリーカード等 の半導体や、MO、磁気ディスク等に代表される磁気記録式、光記録式

等の着脱可能な記録媒体である。

また、類似率算出装置30には、類似率算出装置30の全体の制御を行う情報処理手段380と、情報処理手段380にて実行されるプログラムや各種定数が記録されているROMや情報処理手段380が処理を実行する際の作業領域となる記録手段であるRAMとから構成されるメモリ381とが設けられている。

また、情報処理手段380(クラスタ分解手段、又は類似率算出手段) は、利用者から比較対象の技術文献群に関する情報や、文献同士の比較 条件を入力し、技術文献データベース20から類似率の算出に必要な技 10 術文献を取得し、記録手段384に記録されている類似率の演算プログラムや類似率の算出処理プログラムに基づいて、技術文献同士の類似率 を算出する機能を実現することが可能となっている。また、類似率の算 出結果を表示手段372に表示する機能を実現することが可能となっている。

15 なお、情報処理手段380(クラスタ分解手段)は、文書内の共請求項、発明の詳細な説明、図面の簡単な説明、要約などに含まれる言葉(単語、熟語、名詞、動詞、助動詞、形容詞、副詞、助詞など)からなる文を分かち書きしたり、1字、2字など機械的に切り出して技術文献を検索し、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する。 20 機能を実現することが可能となっている。

また情報処理手段380(クラスタ分解手段)」は、書誌事項などに含まれる項目(IPC等の分類、出願日、出願番号、出願人名、発明者、審査請求の有無、補正の有無、国内優先の有無、外国出願の有無、拒絶理由の有無、登録日、登録番号、など)を用いてクラスタ分解する機能を実現することが可能となっている。

また情報処理手段380 (類似率算出手段) は、クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の、双方の技術文献を含む混在クラスタ数との比を算出するなどして表技術文献群同士の類似率を算出する機能を実現することが可能となってい

る。

25

これらの全ての処理を情報処理手段380が実行する代わりに、複数の処理装置に分担して実行するようにしても本発明の目的を達成することが可能である。

また、類似率算出装置30には、類似率算出装置30の処理に関する 各種定数やネットワーク上の通信機器に通信接続する際の属性情報。U RL (Uniform Resource Locators)、ゲートウェイ情報、D.N.S (Domain Name System)等の接続情報、企業の経営に関する情報、特許に関する 情報、特許文献、技報、キーワード、技術情報等の各種情報を記録する ことが可能なハードディスク等の記録手段384と、記録手段3846 記録されている情報を読み出したり記録手段384に対して情報を書 き込む処理を行う記録手段インターフェース385 (技術文献群入力手 段、技術情報入力手段、又は出力手段の機能を含むものであってもよい) と、時刻を刻むカレンダ時計390とが設けられている。

15 類似率算出装置30内の情報処理手段380と、表示インターフェース373、メモリ381、記録手段インターフェース385、カレンダ時計390等を含む各周辺回路はバス399で接続されており、情報処理手段380にて実行される処理プログラムに基づいて各々の周辺回路を制御する機能を実現することが可能となっている。

20 前記送受信手段 3 6 5、記録媒体インターフェース 3 7 9、記録手段 インターフェース 3 8 5 等の技術情報入力手段は、比較対象となる第4 の技術文献群及び第 2 の技術文献群を入力することが可能となってい る。

前記送受信手段365、入力手段370、入力インターフェース37 1、記録媒体インターフェース379、記録手段インターフェース38 5等の技術情報入力手段は、キーワードやIPCなどの技術情報を入力 することが可能となっている。

前記送受信手段365、表示インターフェース373、記録手段インターフェース385、記録媒体インターフェース379。プリスタティ

**1**5

20

ンターフェース等の出力手段は、類似率算出手段が算出した類似率を、記録手段、表示手段、又は通信手段に出力することが可能となっている。 図1に示したデータベース20は、記録手段384に記憶されている 場合や、CD-ROM、CD-RW、DVD、MO等の記憶媒体377で提供される場合、通信網364を介して他の通信機器から取得する場合も考えられる。

また、上記の類似率算出装置3.0は、パーソナルコンピュータ、ワークステーションなど様々なコンピュータを利用して実現することができる。さらに、コンピュータをネットワークで接続して機能を分散して実施するようにしても良い。

本発明に係る類似率算出装置並びに類似率算出プログラムによって 算出される技術文献の類似率とは、第1の技術文献群(技術文献A群) と別の第2の技術文献群(技術文献B群)とを所定のキーワードや手P。 Cなどに基づいてマクロ的に比較した際に算出される数値であって、技 術文献群同士がどの程度技術的に関連があるかを示す指標とするための数値をいう。

そして、第1の技術文献群(技術文献A群)と第2の技術文献群(技活 術文献B群)は、何らかの属性を持つ技術文献の集まりとする。

本発明では、A社が出願した特許公報やA社が発行した技報などの第2 1の技術文献群(技術文献A群)に記載された技術内容と、B社が出願 した特許公報やB社が発行した技報などの第2の技術文献群(技術文献 B群)に記載された技術内容とが、どれだけ類似しているかを定性的に 評価する指標としての数値を算出することによって、技術文献同士を容 易に比較することが可能となっている。

25 以下に説明する実施例では、第1の技術文献群(技術文献A群)と第 2の技術文献群(技術文献B群)に記載された技術内容が類似している ほど、類似率は大きい値をとるものと定義している。

なお本発明では、類似率を算出する際に異なる条件を設定した場合で あっても、第1の技術文献群(技術文献A群)と第2の技術文献群(技

20

25

術文献 B 群)との間で算出した類似率と、第3の技術文献群(技術文献 C 群)と第4の技術文献群(技術文献 D 群)との間で算出した類似率と を直接比較することが可能であるように、類似率が取り得る範囲として、 0 ≦類似率≦1となるような演算を行なうことにしているが、類似率の 取り得る範囲はこの範囲に限定されるものではない。

図3は、技術文献A群と技術文献B群に含まれる技術文献の構成を示す図である。

同図に示すように、技術文献A群は、A1, A2, A3, AMのMの 個の技術文献から構成されており、技術文献B群は、B1, B2, B3, BNのN個の技術文献から構成されている。

図4は、類似率の表示処理を示すフローチャートである。

同図に示すように、利用者が技術文献群どうしを比較して、技術内容が類似する度合いを調査する場合には、S 1 0 類似率算出指示入力 (以下S 1 0 のように省略して記載する。)において、類似率算出指示を類似率算出装置 3 0 のキーボード、マウス等の入力手段 3 7 0 を操作して入力し、以降の処理を実施させる。

類似率算出装置30が、S100「入力画面読出・表示」にて、類似率算出指示に基づいて、類似率算出に関する各種条件の入力画面の表示情報を記録手段384から読み出して、その表示情報に基づいた類似率に算出に必要な条件の入力画面を表示手段372に表示する。

図5は、類似率算出のための入力画面の表示例を示す図である。

同図に示すように入力画面には、比較対象となっている第1の技術文献群と第2の技術文献群の抽出条件を指定する情報と、キーワードやI\_PCなどの技術情報を指定する旨の情報が表示されている。利用者は、表示画面に基づいて諸事項を入力することが可能となっている。

クラスタ分解の条件を入力する部分では、特許公報、技報等の対象文献の指定や、全文、請求項部分のみ等の対象部分の設定や、IPC、キューワード等のクラスタ分解の尺度等の各種条件を入力することが可能となっている。更に技術文献群の抽出条件として、特許公報の出願日の

期間、業界名称、出典元の企業名、個人名等を入力する項目が表示されている。利用者は、図 5 に示した入力画面に基づいて、容易に類似率の 算出条件を入力したり、予め設けられている複数の算出条件の中から所 望の算出条件を選択することが可能となっている。

5 また図5には、混在クラスタ比を類似率の算出用途に応じて補正する ための、補正方法を入力する部分が設けられている。

例えば補正項1として、各混在クラスタに含まれる技術文献の量に応 じた値に基づいて、類似率を補正するか否かの補正条件を、利用者が入 力することが可能となっている。

10 また補正項2として、各混在クラスタに含まれる第1の技術文献群の 技術文献と第2の技術文献群の技術文献との混ざり具合に応じた値に 基づいて、類似率を補正するか否かの補正条件を、利用者が入力すること とが可能となっている。

なお本発明では、この技術文献との混ざり具合に応じた補正方法として、第1の技術文献群の中からm個、第2の技術文献群の中からm個の技術文献を取り出す確率のγ乗(但し、0<γ)に比例した補正値を各混在クラスタについて総和を算出し、これを全クラスタ数で除算して類似率の補正等を行なう、「技術文献数の確率」に応じた補正方法を選択することが可能となっている。

20 また本発明では、第1の技術文献群に含まれる技術文献数Mと第2の技術文献群に含まれる技術文献数Nとの構成比N/Mと、クラスタ分解した結果得られた混在クラスタに含まれる第1の技術文献群の技術文献数mと第2の技術文献群の技術文献数nの混在比、n/mとについて、更に構成比と混在比との比を取ったもののな乗(但し、0 < な)に比例した補正値を、各混在クラスタについて総和を算出し、これを全クラスタ数で除算して類似率の補正等を行なう、「技術文献の混在比」に応じた補正方法を選択することが可能となっている。

また本発明では、第1の技術文献群と第2の技術文献群とを混合した 技術文献群の中から、第1の技術文献群の技術文献を取り出す確率に、

前記クラスタ分解した混在クラスタに含まれる技術文献数を乗算して 第1の技術文献群の技術文献を取り出す期待値を算出し、期待値と混合。 クラスタに含まれる第1の技術文献群の技術文献数との差を期待値差 として算出し、その期待値差を任意定数 ξ (但し、1 < ξ) の負の指数。 とした補正値を、各混在クラスタについて総和を算出し、これを全クラスタ スタ数で乗算して類似率の補正等を行なう、「技術文献の期待値差」に 応じた補正方法を選択することが可能となっている。

図4に示すS12「類似率算出条件入力」にて、利用者は、表示手段に表示されている案内に基づいて、特許文献、技報、社報、技術論文等の技術文献種別や、比較する技術文献群の指定、クラスタ分解を実施する際に技術文献群から技術文献を抽出する条件となるIPC又はキーフード等、更に類似率を算出する際の目的に応じた補正情報を、入力手段370を介して入力する。

S102「技術文献取得」にて、情報処理手段380は、利用者から 入力した技術文献種別(例えば特許文献)に基づいて検索するデータベースを特定し、利用者から入力した技術文献群(例えばA社の技術文献 A群及びB社の技術文献B群)の指定に基づいた技術文献群の取得情報を特定のデータベースに出力する。

S130「技術文献読出」にて、技術文献データベース20は、類似 20 率算出手段30から取得した技術文献種別と、技術文献群等に基づいて、 データベース内を検索して技術文献を読出して、類似率算出装置3.0に 送信する。

S104「類似率算出処理」にて、類似率算出装置30は、データベース20から取得した技術文献群(例えばA社の技術文献A群及びB社の技術文献B群)の中から、利用者指定のIPCやキーワードを共通して含む技術文献を選び出して、クラスタ毎に分解する処理を行なう。イクラスタ分解した結果、技術文献A群に属する技術文献及び技術文献B群に属する技術文献とが混在しているクラスタを混在クラスタと定義する。本発明では、全クラスタのうち、混在クラスタが存在する割合

に基づいて類似率を算出する。

また、類似率の用途に応じて、混在クラスタに含まれる技術文献の数量や混在確率、混在比率、又はこれらの組合せに応じた補正を行なうるとも可能である。

5 S106「類似率表示処理」にて、類似率算出装置30は、算出した 類似率を表示手段372に表示して、利用者に通知する。なお、S10 6にて類似率を表示手段372に表示する代わりに、算出した類似率を 送受信手段365と通信網10を介して他の通信機器に送信出力する。 ようにしてもよいし、記録手段インターフェース385を介して記録手 10 段384に記録出力するようにしてもよいし、記録媒体インターフェース379を介して記録媒体377に記録出力するようにしてもよい。また、算出した類似率を、印刷用のプリンタインターフェース(図示せず)を介して印刷手段に出力するようにしてもよい。

図6は、類似率算出装置30が算出した類似率を利用者に通知する。 5 類似率表示画面の表示例を示す図である。

同図に示すように、類似率表示画面には、利用者が入力した技術文献 群を抽出指定する情報と、キーワードやIPCなどの技術情報をクラス タ分解した際の尺度や、補正方法等の入力情報が確認のために表示され ている。

20 また類似率表示画面には、補正項3として、例えばクラスタ分解した際の所定の特許分類やキーワードに注目して恣意的な重み付けを行なっための補正条件を、各クラスタ毎に利用者が入力することが可能となっている。同図に示す例では、補正項3の数値として「1.0000」を設定している。

25 また類似率表示画面には、類似率の算出結果と、その類似率を補正するための、α、γ、ζ、ξ等の類似率算出条件を連続的に変更するスラーイドバーと、各クラスタの補正項を確認するために、分解したクラスターの内容を表示する部分が設けられている。

利用者は、算出された類似率を見ながら、自由に類似率の算出条件を

変更することが可能となっている。利用者がスライドバーを操作した場合には、情報処理手段380がカレンダ時計390が係数する時間に基づいて、スライドバーの操作完了を判断する。すると、情報処理手段380が実施する処理はS104に分岐して再度類似率を算出し、類似率の演算結果を類似率表示画面に表示する処理を行なう。

図4に示すS14「終了」、S108「終了」及びS140「終了」。 にて、類似率算出処理が終了する。

本発明における技術文献のクラスタ分解とは、第1の技術文献群(A-群)と第2の技術文献群(B群)をマクロ的に比較するための「類似率」 10 を算出する際に、キーワードや LPC等を用いて技術文献を分類すること とをいう。

本発明を創作するにあたって比較する2つの技術文献群を鳥瞰してみたとき、2つの技術文献群が別々になっていると、非常に計算が複雑になるが、2つを「混ぜて」しまって整理整頓すればずっと計算が容易になるのではないかと、エイヤと「混ぜた」ら案の定類似率の算出に適した様子が見えてきた。双方の技術文献群を混ぜた後、クラスタ分解により分類したところ、一部に両方の技術文献群の構成要素(技術文献)を含むクラスタ(混在クラスタ)が存在し、その分解した全クラスタ数に対する混在クラスタの割合が、我々の通常の感覚としての類似率に近いことがわかった。

先ず、上記のように第1の技術文献群と第2の技術文献群の双方の技術文献を混ぜてひとつの群にする。

混ざった技術文献の群を、何らかの分類法により、ある技術文献の小 さな集まり(クラスタという)に分解する。あるクラスタには第1の技 術文献群に属する技術文献がm個と第2の技術文献群に属する技術文 献がn個含まれているとする。

技術文献をIPC(国際特許分類)毎や、技術文献に所定のキーワードが含まれるか否かによって「グループ分け」することを「クラスタ分解」すると定義する。

図7に、本発明に係る類似率算出装置を用いて技術文献群をクラスタ 分解した後の各クラスタの構成を示す。

例えば図7に示すように、IPC-FG06F17/30」に分類される技術文献として、第1の技術文献群には「特許文献A1」が、また第2の技術文献群には「特許文献B1」がそれぞれ存在した場合には、IPC-FG06F17/30」のクラスタには、「特許文献A1」と「特許文献B1」の要素が含まれる。

また例えば、キーワードとして「テキスト処理」という文言を含む技術文献が、第1の技術文献群には「技術文献A2」が、また第2の技術文献群には「技術文献B2」及び「技術文献B3」が存在した場合には、キーワード「テキスト処理」のクラスタには「技術文献A2」と「技術文献B2」、「技術文献B3」の要素が含まれる。

10

20

25

なお、クラスタ分解の方法には、技術文献群の個々の技術文献の属性 により 2 通りの扱いがあり、それは以下の通りである。

- 15 1. 外的な基準がある属性(属性1型と定義する)の場合は、その属性である。例えば、特許公報等の技術文献でいえば、出願日の日付やIPCなど、一意に決まる技術文献である。
  - 2. 内的な関係で属性が決まる値(属性・2型と定義する)は、前処理として多変量解析(クラスタ分析)などによるクラスタ化が必要である。例えば特許公報技術文献の中では、要約や請求項などの文書に外的な基準をあてはめることが難しいため、文書間のミクロ的な類似率を別途定義し、それに基づいて多変量分解を行った結果を用いてクラスタを構成する。なお、文書間のミクロ的な類似率については、TFIDF法など、一般的に広く用いられているものを使用することにより、分析者の恣意の混入を防ぐことが可能である。

情報処理手段380等のクラスタ分解手段は、第1の技術文献群及び 第2の技術文献群に含まれる技術文献について、技術情報入力手段を介 して入力した技術情報を含む技術文献を検索し、該検索した技術文献を それぞれの技術情報毎にクラスタ分解している。

25

本発明の実施例では、混在クラスタを以下のように定義する。

図7に示すIPC「G06F 1.7/30」のクラスタには、技術文献A群に属する「特許文献A1」と、技術文献B群に属する「特許文献B1」とが混在している。このように、技術文献A群に属する技術文献、 及び技術文献B群に属する技術文献が混在しているクラスタを混在クラスタと定義する。

本発明の実施例では、非混在クラスタを以下のように定義する。

例えば図7に示すように、IPC 「B01」に分類される技術文献として、技術文献A群には「特許文献A-3」が存在するが、技術文献B群には「特許文献A-3」が存在するが、技術文献B群には「PC「B01」に分類される技術文献が存在しない場合には、サートで「B01」のクラスタには「特許文献A3」のみが要素として含まれる。

また図7に示すように、例えばキーワードとして「無機化合物」という文言を含む技術文献は、技術文献A群には存在しないが技術文献B群には「技術文献B1」が存在した場合には、キーワード「無機化合物」のクラスタには「技術文献B1」が要素として含まれる。

このように、技術文献A群に属する技術文献と、技術文献B群に属する技術文献とが混在していないクラスタを非混在クラスタと定義する。 図8は、類似率の算出処理を示すフローチャートである。

20 情報処理手段380が実施する処理が、図4に示したS104に進むと、 情報処理手段380が実施する処理はS200に分岐してきて、S20 0以降の処理を実施する。

類似率算出装置30の情報処理手段380は、S200「技術文献A 群と技術文献B群とを混同する」にて、S10-2「技術文献取得」によってデータベースから取得した技術文献群(例えばA社の第4の技術文献群及びB社の第2の技術文献群)を混合して、1つの技術文献群にする処理を行なう。

S202「クラスタ分解処理」にて情報処理手段380は、キーワードやIPC等の技術情報に基づいてクラスタ分解処理を行う。次のS2

04「補正項1の計算式を設定」にて、情報処理手段380は、混在クラスタに含まれる技術文献の数量に応じて類似率を補正する旨の指示を利用者から入力している場合には、その指示に基づいた補正項の数式を選択する処理を行なう。ここでは、補正の内容に応じて補正項1に所定の数式を代入する処理を行なう。

補正項1は、混在クラスタに含まれる技術文献の量が多い程、重要な クラスタであると考えて類似率が高くなるように重い重み付けをして 類似率の補正を行なうための補正項である。

混在クラスタに含まれる技術文献の数量に応じて類似率を補正しな 10 い場合には、補正項1=1-(定数)を代入する。

S206「補正項2の計算式を設定」にて情報処理手段380は、混在クラスタに含まれる技術文献Aと技術文献Bとの混ざり具合に応じて類似率を補正する旨の指示を利用者から入力している場合には、その指示に基づいた補正項の数式を選択する処理を行なう。ここでは、補正0内容に応じて補正項2に所定の数式を代入する処理を行なう。

補正項2は、混在クラスタに含まれる技術文献の割合が所定の量に近い程、重要なクラスタであると考えて類似率が高くなるように重い重み付けをして類似率の補正を行なうための補正項である。

混在クラスタに含まれる技術文献の混ざり具合に応じて類似率を補 20 正しない場合には、補正項2=1 (定数) を代入する。

S208「補正項3の値を設定」にで情報処理手段3:80は、クラスタ分解した際の所定の特許分類やキーワードに注目して恣意的な重み付けを行なって、類似率を補正する旨の指示を利用者から入力している場合には、その指示に基づいた補正項の数式を選択する処理を行なう。ここでは、補正の内容に応じて補正項3に所定の値を代入する処理を行なう。クラスタ分解した際の所定の特許分類やキーワードについて特に注目しない場合には、補正項3=1 (定数) を代入する。

S210「類似率算出」にて情報処理手段380は、各混在クラスタ について補正項1、補正項2、補正項3の各補正項を乗算して総和を算

出する。更に規格化するために全クラスタ数で除算して類似率を算出する処理を行なう。

S212「終了」にて、類似率算出処理のサブルーチンを終了して、 元の処理に戻る。

5 図9に、類似率の計算に用いる設定条件を示す。

図9は比較対象となる第1の技術文献群及び第2の技術文献群と、各群の技術文献を4つのクラスタに分解した場合の各クラスタ1~4に存在する各技術文献数を示す図表である。同図右端に示す「期待する類似率」の値は、技術文献の類似性の判断を行なっている複数の専門家にヒアリングを行なった結果、条件1~4の場合に、算出されることを期待する類似率の値を示したものである。そして、その期待する類似率の値に対して許容され得ると思われる範囲は、同図に示すように許容範囲=±0.050程度である。

したがって、本発明に係る類似率算出装置を用いて類似率を算出した 5 結果、図9に示す許容範囲内で類似率が算出されれば、技術文献同士の 比較が最適に行なわれていることを示している。

基本型1:補正項を考慮しない場合の類似率(基本型1)の算出例 以下に、補正項を用いない基本型の類似率(基本型1)の算出例を示す。この類似率(基本型1)の算出例は、混在クラスタ抽出法により技術文献の類似率を演算するものである。

第1の技術文献群に含まれる技術内容と、第2の技術文献群に含まれる技術内容とが、どれだけ類似しているかの度合(類似率の値の大きさ)は、「混在クラスタの数量」に比例するものと考えられる。

また類似率を、0 ≦類似率≦1の範囲に設定するために、例えば、「混 25 在クラスタ数」を、「混在クラスタ数と非混在クラスタ数の総和」であ る「全クラスタ数」で除算した混在クラスタを算出すると、技術文献群 同士の類似率として以下の(式 1)が得られる。

混在クラスタを考慮した類似率算出方法を混在クラスタ抽出法と定義する。下記に示す(式1)は最も基本的な考え方である。下記の(式

1)では、クラスタ分解した結果得られた全クラスタ数と、第1の技術 文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数 との比(以下混在グラスタ比と呼ぶ)を類似率として算出する一例を示 している。したがって、全クラスタ数と混在クラスタ数の比の算出のし かたは、下記の(式1)に限定されるものではない。

# 類似率 (基本型 1) = $\frac{1}{2}$ (式 1) = $\frac{20.5248}{20.525}$ (式 1) = $\frac{20.5248}{20.525}$ (式 1)

但し、

δ=混在クラスタの場合……1

10 非混在クラスタの場合…0

先に述べたように、類似率とは第1の技術文献群に記載されている技術内容と第2の技術文献群に記載されている技術内容とがどれだけ類似しているかを示す数値である。

15 また、混在クラスタ数とは、第1の技術文献群に属する技術文献及び 第2の技術文献群に属する技術文献が混在しているクラズタの数を示 す数値である。

全クラスタ数とは、第1の技術文献群の技術文献又は第2の技術文献 群の技術文献が存在するクラスタの全数を示す数値である。

20 以下に、類似率(基本型1)の計算式を用いた場合の計算結果について説明する。

第1の技術文献群と第2の技術文献群について、所定のキーワードや IPC等を用いてクラスタ分解を行なった結果、全クラスタ数が10個 であって、混在クラスタ数が3個であった場合には、類似率(基本型1)

-25 = 3 / 10 = 0.3 と算出される。

また、全クラスタ数が4個であって、混在クラスタ数が2個であった。 場合には、類似率(基本型1) =  $2\sqrt{4}$  = 0 5 2 2 3 出される。

第1の技術文献群と第2の技術文献群に含まれる技術文献を、キーワードやIPC等を用いてクラスタ分解し、その分解した全クラスタ数と、 混在クラスタ数の比を類似率として算出することによって、技術文献群

同士の類似率の基礎部分となる値を算出することが可能となる。

また、類似率を算出する際に、混在クラスタ数を全クラスタ数で除算することによって、算出される類似率の値を、0.≦類似率≦1 の範囲に設定することが可能となる。

10 以下に、類似率(基本型1)を用いた場合の発明の効果について説明 する。

第1の技術文献群と第2の技術文献群に含まれるキーワードやIP C等を用いてクラスタ分解し、その分解した全クラスタ数と混在クラス タ数の比に基づいて類似率を算出することによって、技術文献群同士が どの程度技術的に類似しているかを示す指標を簡便に算出することが 可能となる。ここで算出される類似率は、われわれが常識的に考えた技術文献群同士の類似の程度と割合一致していることがわかった。

また本発明では、算出する類似率の値を 0≦類似率≦1 の範囲に設定する演算を行なっているので、全クラスタ数量や混在クラスタの数量、また技術文献群に含まれる技術文献の量の多少に関わらず一定の指標を算出することが可能となる。

更に、より多くの条件下で第1の技術文献群と第2の技術文献群を比較した類似率と、第1の技術文献群と第3の技術文献群とを比較した類、 似率とを直接対比することも可能となる。

25 基本型 2:補正項を考慮した場合の類似率(基本型 2)の算出例以下に、補正項を考慮した場合の類似率(基本型 2)の算出例を示す。この類似率(基本型 2)の算出例は、前記類似率(基本型 1)の算出例に対して補正項 1~3を加味したものとなっている。

上記の(式1)を用いて類似率を算出すると、混在クラスタ数に比例

15

25

した類似率が簡単な数式を用いてたいへん素早く算出できるという利 点がある。

上記の最も基本的な(式1)は、たとえば多くの技術文献を含むクラスタと少数の技術文献しか含まないクラスタが対等の寄与を持つ結果となることでもわかるように、個々のクラスタ内の技術文献数の大小を考慮していないという欠点があるために、混在クラスタ内に多くの技術文献が含まれない場合で、対応含まれる場合であっても、2つしか技術文献が含まれない場合であっても同一の類似率が算出されてしまい、われわれが常識的に考えた類似の程度と異なってしまう場合があるという不具合を生じる可能性がある。

混在クラスタに含まれる技術文献の量の他にも、混在クラスタに含まれる第1の技術文献群の技術文献と第2の技術文献群の技術文献の混ざり具合(第1の技術文献群の技術文献と第2の技術文献群の技術文献との割合)や、特定の特許分類やキーワードに注目したい場合の恣意的な重み付けなどによって、算出される類似率の値を補正したい場合が生じる。

図10は、混在クラスタ1に技術文献が多く含まれている状況を示す。 図である。

図10に示す例では、クラスター1 (混在クラスタ) には、技術文献が 20 多く含まれているので重要なクラスタであると考えられ、類似率計算の 際に最も寄与が大きくなると良い。

別のクラスタ (例えばクラスタ 2, クラスタ 3, クラスタ 4 など) はまっ 含まれている技術文献が少ないので重要なクラスタではないと思われるので、クラスタ 1 の寄与に比べるとずっと小さくなるのが望ましい。

図10の例のような状況にある場合、クラスタ1に対し、クラスタ2。 クラスタ3,クラスタ4の影響を軽視すべき場合がある。なお、含まれる 技術文献数量が少ないクラスタの存在を無視しない場合には、算出され る類似率の値は0.5まで下がってしまう。

そこで以下の(式2)に示すように、(式1)の $\delta$ -(クラネタが混在

クラスタである場合には $\delta=1$ とし、それ以外の場合には、 $\delta=0$ とする)に対して補正項を乗算することにする。なお、補正によって類似率の範囲が、 $0 \le$ 類似率 $\le 1$  の範囲を超えないようにするためには適当な規格化因子が必要である。

5

15

25

全クラスタ数 × ∑ (補正項1)×(補正項2)×(補正項3)×δ (式2) クラスタ= i

但し、

δ=混在クラスタの場合…… 1

10 非混在クラスタの場合… 0

(式2)に示す補正項1は、混在クラスタに含まれる技術文献の量に 応じて類似率を算出するための補正項である。この補正項1は、混在ク ラスタに含まれる技術文献の量が多い程、重要なクラスタであると考え て類似率が高くなるように重い重み付けをして類似率の補正を行なう 補正項である。

また逆に補正項1は、混在クラスタに含まれる技術文献の量が少ない 程、重要なクラスタでないと考えて類似率が低くなるように軽い重み付 けをして類似率の補正を行なうことも可能な補正項である。

20 また補正項1は、各混在クラスタに含まれる技術文献の量に応じた値 を取る第1の補正値を算出することが可能な他の計算式を用いた補正 項であってもよい。

(式2)に示す補正項2は、混在クラスタに含まれる技術文献Aと技術文献Bの混ざり具合(技術文献Aと技術文献Bの割合)に応じて類似率を算出するための補正項である。

補正項2は、混在クラスタに含まれる技術文献の割合が所定の量に近

25

い程、重要なクラスタであると考えて類似率が高くなるように重い重み 付けをして類似率の補正を行なう補正項である。

また補正項2は、各混在クラスタに含まれる第二の技術文献群の技術 文献と第2の技術文献群の技術文献との混ざり具合に応じた値を取る 第2の補正値を算出することが可能な補正項である。

(式2)に示すように類似率は、補正項1、補正項2、又は補正項3 を全ての混在クラスタについての総和を算出し、該総和を全クラスタ数 で除算する演算を行なっている。

補正項2を算出する際に用いる技術文献の「混ざり具合」の意味は、 10 以下のとおりである。

ある混在クラスタに含まれる第1の技術文献群の技術文献、及び第2 の技術文献群に含まれる技術文献の混ざり具合に注目して、双方の技術 文献がよく混ざっているとき、すなわち双方の技術文献数が偏っていな いときに重要なクラスタと考えて重い重みを付け、よく混ざっていない 場合、すなわち技術文献数が片方の技術文献群のものに偏っている場合 に、重要ではないクラスタと考えて軽い重み付けをするための補正項目 である。

言い換えると、たとえばある混在クラスタに含まれる、第1の技術文献群の技術文献と第2の技術文献群の技術文献の数量が、第1の技術文献群と第2の技術文献群から無作為に抽出したときの期待値に近いものは重く、遠いものは軽くする補正項である。

補正項3とは、特定の特許分類やキーワードに注目したい場合に、恣意的な重み付けを行なって類似率を算出するための補正項である。この項は技術文献群同士を比較する者が個別設定する項であるので、今回は考慮せずに定数「1」を代入しておる。

応用型1:補正項1(1)の算出例。

15

20

補正項1 (1) = 
$$\frac{(クラスタ内の技術文献数)^{\alpha}}{(規格化因子)}$$
 =  $\frac{(クラスタ内の技術文献数)^{\alpha}}{1}$  =  $\frac{1}{2^{2}\sqrt{2}\sqrt{2}}$  (式3)  $\frac{1}{2^{2}\sqrt{2}\sqrt{2}\sqrt{2}}$  (プラスタ内の技術文献数)

補正項1(1)を考慮した類似率(式4)の算出例を以下に示す。

$$= \frac{1}{\frac{1}{2^{2}}}$$

$$\times \sum_{\substack{2^{2} \neq 3^{2} \neq 0 \\ 2^{2} \neq 3^{2} \neq 0}}^{\frac{2}{2}} \left\{ \frac{(2^{2} + 2^{2}$$

補正項1 (1) では、類似率が混在クラスタに含まれる技術文献の量に応じて大きな値をとるように補正するために、「クラスタ内の技術文献数」の $\alpha$ 乗(但し、 $0 < \alpha$ )を分子に配置している。そして、類似率の算出範囲として  $0 \le$ 類似率 $\le 1$  を保証するために、補正項1(1)。の式では規格化因子を分母に配置している。

(式4)に示す補正項1 (1)の演算では、分子に配置したクラスター 内の技術文献数が多い場合であっても類似率の値が1を超えないようにするためと、技術文献の量の多少の判断基準を設けるために、規格化因子として、全クラスタ内の技術文献数の平均値を配置している。なお、規格化因子は、全クラスタ内の技術文献数の $\alpha$ 乗の総和を算出し、全クラスタ数で除算した値を配置してもよい。この規格化因子は、 $0 \le$ 類似率 $\le 1$  を保証することが可能な項であればよく、(式4)の数式に限定されるものではない。

更に、含まれる技術文献の量が少ない混在クラスタの影響を、類似率

の算出結果に大きく反映させたくない場合には、分子の指数  $\alpha$  を  $\alpha$  > 1 に設定する。

また、単純にクラスタ内の技術文献数の量に応じて類似率を増減させる要望がある場合には、 $\alpha=1$  に設定する。

5 また、クラスタに含まれる技術文献の量に応じて類似率を算出するとともに、技術文献が多量に含まれるクラスタの存在による類似率の算出結果の影響を少なくする必要がある場合には、0 < α < 1 に設定するとよい。

以下に「応用型1:補正項1(1)」の計算式の分子と分母の構成に 10 よる作用について説明する。

式4に説明するように「クラスタ内の技術文献数」を補正項1 (1) の分子に配置したので、クラスタ内の技術文献数に比例した類似率を算出することが可能となる。

また、「規格化因子」を補正項1 (1)の分母に配置したので、0≦ 15 類似率≤1 を保証することが可能となる。そして、補正項1 (1)の 規格化因子として、全クラスタ内の技術文献数の平均値を配置したので 全クラスタ内の技術文献数の平均値を基準として、技術文献の量の多少 を算出することが可能となる。

更に、分子の指数  $\alpha$  を  $\alpha$  >1 に設定することによって、混在クラスタに含まれる技術文献の量が少ない混在クラスタの影響を、類似率の算出結果に大きく反映させないようにすることが可能となる。また、分子の指数  $\alpha$  を  $\alpha$  に設定することによって、単純にクラスタ内の技術文献数の量に応じて類似率を増減させることが可能となる(単純含数比較)。また、分子の指数を  $\alpha$  < 1 に設定することによって、技術文献が多量に含まれるクラスタの存在による類似率の算出結果の影響を少なくすることが可能となる。

.20

25

以下に、「応用型1:補正項1(1)」の計算式(式4)に、図9に示した各条件を代入した場合の計算例を示す。なお、算出結果は、図11に、補正項1(1)を採用した場合の類似率算出例(補正項1)(1)に

条件1~4を代入した場合の計算結果)の図表として示す。

補正項1(1)のみを考慮して他の補正項を考慮しない場合であって (すなわち補正項2=1、補正項3=1とする)、単純に混合クラスタ 内に含まれる技術文献数の比較を行なう場合(すなわち $\alpha=1$ としたと き)に、技術文献群同士を比較する条件として、条件 $1\sim4$ を設定した 場合の類似率の試算結果を以降に示す。

下式(式5)に、計算例4-1元(式4に条件1を代入した場合)の計画 算結果について説明する。

条件1の場合には、各混在クラスタ(本実施例の場合には、クラスタ 10 1及びクラスタ2)に含まれる技術文献数は、それぞれ3個である。し たがって、クラスタに含まれる技術文献の量による類似率の補正の影響 は少ないことが期待される。

15

上記(式5)にて算出した類似率(式4に条件1を代入した場合) = 0.5 の値は、(式1)による類似率の演算結果と一致しておか、補正項1(1)を挿入した場合であっても、われわれが常識的に考えた類似率の程度と大きくずれてはいない。また、クラスタ内の技術文献数量がそれぞれ3、3、2、4程度であるので、全てから同じ程度の寄与があるべきで、ここで類似率=0.5 と算出された結果は、われわれが常識的に考えた類似の程度(約 0.30 程度)から大きく外れてはおらず、おおよそ要件を満足しているものとなっている。

下式(式6)に、計算例4-2 (式4に条件2を代入した場合)の計画 算結果について説明する。

条件2の場合のクラスタ1に含まれる技術文献の量は、クラスタ2~1 クラスタ4に含まれる技術文献の量よりも際立って多いので、類似率を 第出する際には、クラスタ1に含まれる技術文献の量の影響を重視して 類似率を大きく算出するべきなのは明らかである。

類似率(式 4 , 条件 2 ) =  $\frac{1}{2}$   $\frac{1$ 

 $=\frac{1}{4}\left(\frac{150}{(150+3+2+4)/4}+\frac{3}{(150+3+2+4)/4}\right)=0.962 ...(\pm 6)$ 

10 上記(式6)にて算出した類似率(式4に条件2を代入した場合)= 0.962の値は、クラスタ1に含まれる技術文献の量の多さに引っ張られ、類似率=0.5(式4に条件1を代入した場合に算出した類似率)から類似率 0.962(式4に条件2を代入した場合に算出した類似率)に補正された。

15 以下に式6(式4に条件2を代入した場合)の効果について説明する。 式6の演算処理によって、クラスタに含まれる技術文献の量が他のクラニスタに含まれる技術文献の量よりも多い場合に、その技術文献の量を類似率の算出結果に反映させることが可能となる。これは、クラスタ1が 類似率を算出する際の傾向のほぼ全でを代表しているので、このクラス 20 タ1の性質が類似率を決めるように働いているのが見える。

そしてこの類似率の算出結果は、われわれが常識的に考えた類似の程 度と、かなり一致していることがわかった。

下式(式)に、計算例4-3(式4に条件を3代入した場合)の計算と

結果について説明する。

条件3の場合には、条件2の場合とクラスタに含まれる技術文献の量の総和は同じであるが、クラスタ1に含まれる技術文献の量のみが際立って多い状況ではないので、類似率を算出する際にクラスタ1に含まれる技術文献の量の影響が条件2の場合程は生じないことが望ましい。

類似率(式 4 , 条件 3 ) =  $\frac{1}{2\sqrt{2}\sqrt{3}}$  (補正項 1-)×(補正項 2 )×(補正項 3 )× $\delta$  )  $\frac{1}{2\sqrt{2}\sqrt{2}\sqrt{2}}$  (クラスタ内の技術文献数)  $\frac{1}{2\sqrt{2}\sqrt{2}\sqrt{2}\sqrt{2}}$  (クラスタ内の技術文献数)  $\frac{1}{2\sqrt{2}\sqrt{2}\sqrt{2}\sqrt{2}}$  (クラスタ内の技術文献数)

$$=\frac{1}{4}\left(\frac{70}{(70+3+82+4)/4}+\frac{3}{(70+3+82+4)/4}\right)=0.459$$

上記(式7)にて算出した類似率(式4に条件3を代入した場合) 0.459の値は、クラスタ1に含まれる技術文献の量の多さが、他のクラスタ3よりも少し少ない程度であることから、類似率の補正にはほとんど関与しないように補正される。

以下に、(式7)の計算結果(式4に条件3を代入した場合)の効果 15 について説明する。

補正項1(1)の演算処理を行なうことによって、クラスタに含まれる技術文献の量が多い場合であっても、他のクラスタに含まれる技術文献の量と大差が無い場合には、その技術文献の量を類似率の算出結果にあまり反映させないようにすることが可能となる。

20 この(式7)による類似率の算出結果は、クラスタ1とクラスタ3の 影響が大きく出るように補遺性が働いているので、われわれが常識的に 考えた類似の程度(約 0.20 程度)と大きくずれてはおらず、ほぼ狙い どおりの値が得られている。 下式(式8)に、計算例4-4 (式4に条件を4代入した場合)の計算結果について説明する。

条件4の場合には、条件3の場合とクラスタに含まれる技術文献の量の総和は同じであるが、クラスタ1及びクラスタ2に含まれる第1の技術文献群と第2の技術文献群との割合が極端に不均等である場合である。したがって、混合クラスタに含まれる技術文献数が多いからといって類似率を大きく算出しないことが望ましい。

$$= \frac{1}{2} \frac{\frac{2}{2} \frac{2}{5} \frac{2}{$$

 $=\frac{1}{4}\left(\frac{1}{(5\ 2+2\ 1+8\ 2+4)/4} + \frac{1}{(5\ 2+2\ 1+8\ 2+4)/4}\right) = 0. -459 - \dots (\sharp 8)$ 

10

20

上記の(式8)にて算出した類似率(式4に条件4を代入した場合) =0.459の値は、クラスタ1及びクラスタ2に含まれる技術文献の量が 多くても、他のクラスタ3よりも少し少ない程度であることから、類似-率の補正にはほとんど関与しないように補正される。

15 以下に、(式8)の計算結果(式4に条件4を代入した場合)の効果 について説明する。

(式8)の演算処理によって、クラスタに含まれる技術文献の量が多い場合であっても、他のクラスタに含まれる技術文献の量と大差が無い場合には、その技術文献の量を類似率の算出結果にあまり反映させないようにすることが可能となるが、条件4の場合には類似率は数パーセントの値になることが感覚上望ましい。

この条件4の場合には、補正項1、(1)の処理だけでは人の感覚と一致しない部分が生ずる可能性があるために、以降で説明する補正項2が有用となる。但し、クラスタ3、1、2の影響が大きくなっているので、

補正項1(1)の役割は十分に果たしているといえる。また、補正項1 (1)の処理を行なうことによって、技術文献数の多いクラスタが存在 する場合には、そのクラスタに含まれる技術文献数量の多さを類似率に 反映することが可能となっている。

5 図11に、補正項1(1)を採用した場合の類似率算出例。(補正項1 (1)に条件1~4を代入した場合の計算結果)の図表を示す。

応用型2:補正項2(1)の算出例

以下に示す補正項2(1)の計算式(式9)は、混在クラスタ内の技術文献の混在確率に応じて補正を行なうために構成したものである。

10

補正項2 (1) = 
$$\frac{(混在確率)^r}{(混在確率の最大値)^r}$$

= (A群の中からm個、B群の中からn個の技術文献を取り出す確率)\*(A群の中からx個、B群の中からy個の技術文献を取り出す確率)\*

(A群の中からm個、B群の中からm個の技術文献を取り出す組合せ数 A群とB群とを混ぜ合わせた中からm+n個の技術文献を取り出す組合せ数)

A群の中からx個、B群の中からy個の技術文献を取り出す組合せ数 A群とB群とを混ぜ合わせた中からm+n個の技術文献を取り出す組合せ数

$$= \frac{\left(\frac{M^{C_{m} \times N^{C_{n}}}}{M+N^{C_{m+n}}}\right)^{r}}{MAX\left(\frac{M^{C_{x} \times N^{C_{y}}}}{M+N^{C_{m+n}}}\right)^{r}} \dots (\cancel{\Xi}\cancel{9})^{r}$$

但し、

M:第1の技術文献群 (A群)に含まれる技術文献数

15 N:第2の技術文献群 (B群) に含まれる技術文献数

m:所定のクラスタに含まれる第1の技術文献群 (A群) の技術文献数

n:所定のクラスタに含まれる第2の技術文献群 (B群)の技術文献数

γ:任意定数 γ > 0

上記補正項2(1)を考慮した類似率(式10)の算出例を以下に示す。

5

10

15

(式10)の補正項2(1)では、類似率が、混在クラスタに含まれる第1の技術文献群(A群)及び第2の技術文献群(B群)の技術文献数の確率に応じて大きな値をとるように補正するために、第1の技術文献群(A群)の中からm個、第2の技術文献群(B群)の中からm個の技術文献を取り出す確率のγ乗(但し、0<γ)を分子に配置している。

類似率の算出範囲を  $0 \le$ 類似率 $\le 1$  を保証するために、例えば (式 10) に示すように、第 1 の技術文献群 (A群) の中から m 個、第 2 の技術文献群 (B群) の中から m 個の技術文献を取り出す確率の最大値の $\gamma$ 乗 (但し、 $0 < \gamma$ ) を規格化因子として分母に配置している。

規格化因子は、0 ≦類似率≦ 1= を保証することが可能な項であれば よく、(式 1 0) に示した規格化因子に限定されるものではない。

以下に、指数γの設定条件について説明する。

20 単純に混在クラスタに含まれるA群及びB群の技術文献数が、A群及びB群の技術文献群から無作為に抽出した際の分布に近い度合いに比

. 5

10

20

25

例して類似率の値を補正する必要がある場合には、指数 $\gamma$ を  $\gamma = 1$  に設定するとよい。

また、混在クラスタに含まれるA群及びB群の技術文献数が、A群及びB群の技術文献群から無作為に抽出した際の分布に近いほど重要視して大きな値に補正する必要がある場合、又は、A群及びB群の技術文献群から無作為に抽出した際の分布に違いほど軽視して小さな値に補正する必要がある場合には、指数ッをファントに設定するとよい。

また、混在クラスタに含まれるA群及びB群の技術文献数が、A群及びB群の技術文献群から無作為に抽出した際の分布に近くなくても重要視して補正する必要がある場合には、指数 $\gamma$ を  $0 < \gamma < 1$  に設定するとよい。

以下に、応用型2:補正項2(1)の計算式(式1:0)に,図9に示した各条件を代入した場合の計算例を示す。なお、算出結果は、図12に、補正項2(1)を採用した場合の類似率算出例(補正項2(1)に条件1~4を代入した場合の計算結果)の図表として示す。

補正項2(1)では、(A群の中からm個、B群の中からm個の技術文献を取り出す組合せの数)/(A群とB群とを混ぜ合わせた中からmとれて、混在クリスタに含まれるA群及びB群の技術文献数の偏り(作為性)に応じて、偏り大の場合は小さい補正値に、偏り小の場合は大きい補正値に類似率を補正することが可能となる。本実施例では、偏りが大きい場合には補正値を小さくして類似率を小さく算出することとし、逆に偏りが小さい、場合には補正値を大きくして類似率を大きく算出することとしている。

規格化因子として分母に(A群の中から x 個、B 群の中から y 個の技術文献を取り出す組合せの数)/ (A群とB群とを混ぜ合わせた中からm+n 個の技術文献を取り出す組合せ数)を配置したので、x、y は分母を最大にする数の組合せであることから類似率の算出範囲として0 ≤類似率≤1 を保証することが可能となる。

- 更に、分子の指数γを γ=1 に設定することによって、単純に混-

在クラスタに含まれるA群及びB群の技術文献数が、A群及びB群の技術文献群から無作為に抽出した際の分布に近い度合いに比例して類似率の値を補正することが可能となる。

また、分子の指数 $\gamma$ を  $\gamma$  > 1 に設定することによって、混在クラスタに含まれるA群及びB群の技術文献数が、A群及びB群の技術文献群から無作為に抽出した際の分布に近いほど重要視して大きな値に補正することが可能となる。また、A群及びB群の技術文献群から無作為に抽出した際の分布に遠いほど軽視して小さな値に補正することが可能となる。

10 また、混在クラスタに含まれるA群及びB群の技術文献数が、A群及びB群の技術文献群から無作為に抽出した際の分布に近くなくでも重要視して補正する必要がある場合には、分子の指数γを 0 < γ < 1 に設定するとよい。

下式(式11)に、計算例10-1(式10に条件1を代入した場合) 15 の計算結果について説明する。

補正項2(1)のみを考慮して他の補正項の作用を考慮しない場合であって(すなわち補正項1=1、補正項3=1とする)、単純に混在確率に基づいて比較を行なう場合(すなわちッ=1とした場合)に、技術文献群同士を比較する条件を、条件1~4に設定したときの類似率の試算結果は、以下のとおりである。

下記の(式11)に示すように、条件1の場合には、各混在クラスタ 1に含まれる技術文献の混在確率は、0.409と算出される。また、 同様にクラスタ2に含まれる技術文献の混在比率も、0.409と算出 される。

25

20

混在確率(条件 1, クラスタ 1) = 
$$\begin{pmatrix} MC_m \times_N C_n \\ M+NC_{m+n} \end{pmatrix}$$
 =  $\begin{pmatrix} 6C_2 \times_6 C_1 \\ 6+6C_{2+1} \end{pmatrix}$  =  $\frac{6C_2 \times_6 C_1}{1_2 C_3}$  =  $\frac{15\times6}{220}$  = 0. 409 ...(式 11)

一方、分母の規格化因子は混在クラスタ1の混在確率の最太値である。 ので、以下のように規格化因子=0.4409と算出される。また、条件 1の場合には、クラスタ2の規格化因子も0.4409と算出される。

5

. 10

規格化因子(条件 1, クラスタ 1) = MAX
$$\left(\frac{{}_{M}C_{m}\times_{N}C_{n}}{{}_{M+N}C_{m+n}^{-}}\right)$$
 = MAX $\left(\frac{{}_{6}C_{m}\times_{6}C_{n}}{{}_{6+6}C_{2+1}}\right)$  =  $\frac{{}_{6}C_{2}\times_{6}C_{1}}{{}_{12}C_{3}}$  =  $\frac{15\times6}{220}$  = 0. 409 ...(式 12)

したがって、(式12)の計算式に条件1を代入した場合における補 正項2(1)の値は、補正項2(1)=1と算出される。同様に、混在 クラスタ2の補正項2(1)の値も1と算出される。

したがって、補正項2(1)の値は、下式(式13)のように 1と算出されるので、特に補正は行なわれずに、類似率は0.5と算出される。

類似率(式10,条件1)= 1 (補正項1)×(補正項2)×(補正項3)×δ ( 全クラスタ数: クラスタ表: クラスタ表: クラスタ表: クラスター)

$$= \frac{1}{\frac{1}{275 \times 50}} \left\{ 1 \times \frac{\left(\frac{MC_{m} \times_{N} C_{n}}{M+NC_{m+n}}\right)^{r}}{MAX \left(\frac{MC_{x} \times_{N} C_{y}}{M+NC_{m+n}}\right)^{r}} \times 1 \times \delta \right\}$$

$$= \frac{1}{4} \left( \frac{0.409}{0.409} + \frac{0.409}{0.409} \right) = 0.5 \qquad ...(式13)$$

15

20

上記の(式13)により算出される類似率(式10に条件1を代入した場合)=0.5の値は、補正を考慮しない(式1)による類似率の演算結果と一致している。そして、技術交献群に含まれる技術文献数量がそれぞれ6個と6個であり、混在クラスタ内に含まれる技術文献数も2個と1個であるので、われわれが常識的に考えた類似の程度とほぼ一致し

ている。したがって、補正項2(1)を挿入した場合であっても許容範 囲内の結果を得ることが可能となる。

下式(式14)に、計算例10-2(式10に条件2を代入した場合)。 の計算結果について説明する。

- 条件2の場合のクラスタ1に含まれる技術文献の混在確率は、第1の 技術文献群(A群)と第2の技術文献群(B群)の大きさの比率に近い ので、類似率を算出する際にはクラネタ1を構成する技術文献の混在比 率の影響を重視して、類似率を大きく算出するべきな のは明らかである。
- 10 以下の(式14)に、補正項2(1)の分子を構成する混在確率の計算例を示す。

混在確率 (条件2, クラスタ1) = 
$$\left(\frac{{}_{M}C_{m}\times_{N}C_{n}}{{}_{M+N}C_{m+n}}\right)$$
 =  $\left(\frac{{}_{104}C_{100}\times_{65}C_{50}}{{}_{104+55}C_{100+50}}\right)$  =  $\frac{{}_{159}C_{150}}{{}_{159}C_{150}}$  =  $\frac{4598126\times3478761}{1.42E+14}$  = 0. 113 ...(式14)

15 一方、分母の規格化因子は混在クラスタ1の混在確率の最大値である。 ので、以下のように規格化因子=0.280と算出される。また、条件 2の場合には、クラスタ2の規格化因子も0.280と算出される。

規格化因子(条件 2, クラスタ 1) = MAX
$$\begin{pmatrix} MG_{m}X_{N}C_{n} \\ M+NC_{m+n} \end{pmatrix}$$
 =  $\begin{pmatrix} 10.4C_{9.8}X_{5.5}C_{5.2} \\ 10.4+5.5C_{9.8+5.2} \end{pmatrix}$  =  $\frac{10.4C_{9.8}X_{5.5}C_{5.2}}{10.4+5.5C_{9.8+5.2}}$  =  $\frac{1.52E+09\times26235}{1.42E+14}$  = 0. 280 ...(式 1.5)

20

したがって、条件 2 におけるクラスタ 1 の補正項 2 (1) の値は、補正項 2 (1) = 0.404 と算出される。また、条件 2 におけるクラスタ 2

の補正項2(1)の値は、「1」と算出されるので、下式(式16)に 示すように、補正項2(1)に基づく類似率は0.351と算出される(図 12参照)。

上記の(式16)にて算出した類似率(式10に条件2を代入した場合) =0.351の値は、クラスタ1に含まれる技術文献の混在確率に引っ 張られ、類似率(式4に条件2を代入した場合) =0.962から、類似率 (式5に条件2を代入した場合) =0.351に補正された。

下式 (式17) ~ (式19) に、計算例10-3 (式10に条件3を 代入した場合)の計算結果について説明する。以下の(式17)は、補 正項2 (1)の分子を構成する混在確率の計算例である。

混在確率(条件3, クラスタ 1) = 
$$\left(\frac{{}_{M}C_{m}\times_{N}C_{n}}{{}_{M+N}C_{m+n}}\right)$$
 =  $\left(\frac{{}_{104}C_{20}\times_{66}C_{60}}{{}_{104+86}C_{20+60}}\right)$  =  $\frac{{}_{104}C_{20}\times_{66}C_{60}}{{}_{169}C_{70}}$  =  $\frac{1.28E + 21 \times 3478761}{1.49E + 46}$  = 2.98E - 19 = 0, 000 ...(式17)

15

10

一方、分母の規格化因子は混在クラスタ1の混在確率の最大値であるので、以下のように規格化因子=0.133 と算出される。また、条件3の場合には、クラスタ2の規格化因子も0.448と算出される。

規格化因子(条件3, クラスタ1) = MAX 
$$\left(\frac{MC_m \times_N C_n}{M+NC_{m+n}}\right) = \left(\frac{104 C_{46} \times_{56} C_{24}}{104+66 C_{46+24}}\right)$$

$$= \frac{104 C_{46} \times_{56} C_{24}}{169 C_{70}} = \frac{7.96E + 29 \times 2.49E + 15}{1.49E + 46}$$
= 0. 133 ....(式18)

5 したがって、条件3における補正項2次(1)。の値は、補正項2 (1)。 =0.000 と算出される。混在クラスタ2の補正項2 (1) の値はご条件 1及び条件2の場合と同様に1と算出される。

したがって類似率は、下記の計算によって 0.25 と算出される。

10

15

上記の(式19)にて算出した類似率(式10に条件3を代入した場合)=0.25の値は、クラスタ1に含まれる技術文献の混在確率に引っ張られ、類似率(式4に条件3を代入した場合)=0.459から類似率(式10に条件3を代入した場合)=0.25に補正された。

下式(式20)~(式24)に、計算例10-4(式10に条件4を 代入した場合)の計算結果について説明する。

条件4の場合には、条件3の場合とクラスタに含まれる技術文献の量の総和は同じであるが、クラスタ1及びクラスタ2に含まれる技術文献

A群と技術文献B群との割合が極端に不均等である場合である。したがって、混合クラスタに含まれる技術文献数が多いからといって類似率を大きく算出しないことが望ましい。

補正項2(1)の混在クラスタ1の分子を構成する混在確率<u>について</u> 5 算出すると、

混在確率(条件 4, クラスタ 1) = 
$$\left(\frac{{}_{M}C_{m}\times_{N}C_{n}}{{}_{M+N}C_{m+n}}\right) = \left(\frac{{}_{104}C_{2}\times_{55}C_{50}}{{}_{104+55}C_{2+50}}\right) = \frac{{}_{104}C_{2}\times_{65}C_{60}}{{}_{159}C_{52}}$$
  
=  $\frac{5356\times3478761}{2.98E+42} = 6.26E-33 = 0.000 \dots (式 20)$ 

一方、分母の規格化因子は混在クラスタ1の混在確率の最大値である。 10 ので、以下のように規格化因子=0.141と算出される。

規格化因子(条件 4, クラスタ 1) = MA X 
$$\left(\frac{{}_{M}C_{m}\times_{N}C_{n}}{{}_{M+N}C_{m+n}}\right) = \left(\frac{{}_{1\,0\,4}C_{3.4}\times_{5.5}C_{1\,8}}{{}_{1\,0.4+5\,5}C_{3\,4+1\,8}}\right)$$

$$= \frac{{}_{1\,0\,4}C_{3.4}\times_{5.5}C_{1\,8}}{{}_{1\,6\,9}C_{5\,2}} = \frac{2.91E + 27 \times 1.44E + 14}{2.98E + 42}$$

$$= 0.141 \qquad ...(式 2.1)$$

したがって、条件 4 における混在クラスタ 1 の補正項 2 (1)の値は、 15 補正項 2 (1) = 0.000 と算出される。

一方、混在クラスタ2の補正項2 (1)の値は、以下のように補正項 2 (1) = 0.004 と算出される。

混在確率(条件 4, クラスタ 2) = 
$$\left(\frac{{}_{M}C_{m}\times_{N}C_{n}}{{}_{M+N}C_{m+n}}\right) = \left(\frac{{}_{104}C_{20}\times_{55}C_{1}}{{}_{104+55}C_{20+1}}\right) = \frac{{}_{104}C_{20}\times_{55}C_{1}}{{}_{169}C_{21}}$$
  
=  $\frac{1.28E + 21\times55}{8.34E + 25} = 0.001$  ...(式 2 2)

混在クラスタ2の分母の規格化因子は、混在クラスタ2の混在確率の 最大値であるので、条件4の場合には、以下のように規格化因子=0.194 と算出される。

5 ·

規格化因子(条件 4, クラスタ 2) = MA X 
$$\left(\frac{{}_{M}C_{m}\times_{N}C_{n}}{{}_{M+N}C_{m+n}}\right) = \left(\frac{{}_{104}C_{14}\times_{55}C_{7}}{{}_{104+55}C_{14+7}}\right)$$

$$= \frac{{}_{104}C_{14}\times_{56}C_{7}}{{}_{159}C_{21}} = \frac{7.95E+16\times2.03E+08}{8.34E+25}$$

$$= 0.194 \qquad ...(式 2-3-)$$

したがって類似率は、以下のように 0.-001と算出される。

10

15

上記の(式24)にて算出した類似率(式10に条件4を代入した場合)=0.001の値は、クラスタ1及びクラスタ2に含まれる技術文献の混在確率が、技術文献A群と技術文献B群から無作為に取り出した場合の混在確率の最大値よりもはるかに小さいので、類似率(式4に条件4を代入した場合)=0.459から類似率(式10に条件4を代入した場合)=0.001に補正された。

図12に、補正項2(1)を採用した場合の類似率算出例(補正項2 (1)に条件1~4を代入した場合の計算結果)の図表を示す。 WO 2005/033972 PCT/JP2004/004451

同図に示すように、混合クラスタのうち、技術文献がよく混ざっているクラスタ (混在確率が大きい値を示す条件を備えたクラスタ) では、補正項2 (1) の値が大きい値を示していることがわかる。また、技術文献がよく混ざっていないクラスタ (混在確率が小さい値を示す条件を備えたクラスタ) では、補正項2 (1) の値がほぼ「0」と、小さい値を示し、算出される類似率の値も小さい値を示している。

図13に、補正項1(1)及び補正項2(主)の双方を採用した場合の類似率算出例(補正項1(1)及び補正項2(1)に、条件1~4を代入した場合の計算結果)の図表を示す。

10 条件1の場合に算出された類似率=0.5は、われわれが常識的に考える類似の程度とほぼ合っているといえる。

条件2の場合には、混合クラスタ1に含まれる技術文献の数量はクラスタ2~4に含まれる技術文献数量と比べると明らかに多いが、算出される類似率の値は(式1)に条件2を代入した場合の類似率=0.5から、補正項1(1)及び補正項2(1)を用いて条件2を代入じた場合の類似率=0.4に補正された。このように補正項1(1)及び補正項2(1)を用いて類似率を算出することによって、技術文献数の多いクラスタ1についてあまり重み付けをしたくないときに有効となる。

15

条件3の場合には、条件2の場合と比較してクラスタ内に含まれる技 20 術文献数量の総和は同じだが、混在クラスタ1の技術文献数量のみが特 に多い訳ではないので、算出される類似率の値は類似率=0.019に小さ く補正された。このように補正項1::(1)及び補正項2(1)を用いて 類似率を算出することによって、クラスタ1に含まれる技術文献数量の 多さを類似率の算出結果に反映したぐない場合に有効となる。

25 条件4の場合には、条件2の場合と比較してクラスタ内に含まれる技術文献数量の総和は同じだが、混在クラスタ1、や混在クラスタ2が特に大きい訳ではなく、技術文献の混ざり具合がさらに極端なとき、類似率の値は類似率=0.0005に補正されている。このように補正項1-(1)及び補正項2(1)を用いて類似率を算出することによって、混在クラス

タ内の技術文献数量が多い場合であっても、技術文献の混ざり具合が不 均等である場合には類似率を小さく算出する方向に補正することが可 能となる。

すなわち、補正項1 (1)及び補正項2 (1)を用いて類似率を算出することによって、技術文献数量の多い混在クラスタを重要視して類似率を補正するとともに、技術文献の混ざり具合が不均一な場合には、類似率を小さい値に補正することが可能となる。

また同図に示すように、補正項2 (1)の計算式では、補正項の値が 技術文献の混ざり具合に敏感に反応する傾向があるので、適宜γの値を 調節する必要が生ずる場合もあると考えられる。そして、混在クラスタ 内に含まれる技術文献の数量に基づいた補正と、混在クラスタ内に含ま れる技術文献の混ざり具合に基づく補正とは、上述のようにそれぞれ密 接な関係があるので、αの値とともにγの値を適宜定めることも重要で あると考えられる。

15 なお、図13は $\alpha=1$ 、 $\gamma=1$ とした場合の計算例であるが、例えぼ  $\alpha=1$  のままとして $\gamma=0.25$  に設定して試算してみると、条件1の類似 率=0.5→0.5、条件2の類似率=0.4→0.769、条件3の類似率=0.019 →0.019、条件4の類似率=0.0005→0.033 と算出することが可能となる。

20 応用型3:補正項2(2)の算出例

補正項2(2)は、混在クラスタ内における技術文献の混在比に応じて類似率を補正する補正項である。

第1の技術文献群(A群)と、第2の技術文献群(B群)に含まれる技術文献の数量の比が大きく異なる場合には、各混在クラスタに含まれる技術文献の混在比も当然異なるはずである。また、両群に含まれる技術文献の数量が拮抗しているほど、クラスタに含まれる技術文献の混在比は第1の技術文献群(A群)及び第2の技術文献群(B群)に含まれ技術文献数の数量の比(構成比)に近くなると考えるのが妥当である。そこで本発明では、第1の技術文献群(A群)及び第2の技術文献群

(B群)に含まれる技術文献数の構成比N/Mと、各クラスタ内における技術文献数の混在比n/mについて、更に構成比と混在比との比を取ったものの $\xi$ 乗(但し、 $0 < \xi$ )に比例した補正値を、類似率を算出する際の補正項として設けている。

すなわち、第1の技術文献群 (A群) 及び第2の技術文献群 (B群) に含まれる技術文献数の構成比N/Mと、各クラスタ内における技術文献数の混在比n/mが近いほど類似率を高く設定する (1に近づける) ための数式である。

したがって補正項2(2)の値は、第1の技術文献群(A群)及び第102の技術文献群(B群)に含まれる技術文献数の構成比と、各クラスタ内における技術文献同士の混在比が異なるほど1から小さい値を取る。

補正項2(2) = 
$$\frac{\frac{N}{M}}{\frac{N}{M}}$$
又は $\frac{n}{m}$ の小さい方 
$$= \begin{cases} \frac{N}{N}$$
又は $\frac{n}{m}$ の大きい方 
$$= \begin{cases} \frac{MIN(\frac{N}{M}, \frac{n}{m})}{MAX(\frac{N}{M}, \frac{n}{m})} \end{cases}$$
$$= MIN(\frac{N\times m}{M\times n}, \frac{M\times n}{N\times m})^{\zeta} \dots (式25)$$

15 補正項2 (2) を考慮した類似率の算出例を、以下の (式2.6) に示す。

類似率=
$$\frac{1}{2\sqrt{2}}$$
  $\sum_{\substack{0.52.9 \text{ M} \\ 0.52.9 \text{ M}}}^{2\sqrt{2}52.9 \text{ M}} \left((補正項1) \times (補正項2) \times (補正項3) \times \delta\right)$  =  $\frac{1}{2\sqrt{2}52.9 \text{ M}} \left((in) \times \left(\frac{N}{M}, \frac{n}{m}\right)\right) \times \left(\frac{N}{M} \times \frac{N}{M}, \frac{n}{m}\right)\right)$   $\times (in) \times \left(\frac{1}{M} \times \frac{N}{M}, \frac{n}{m}\right)$   $\times (in) \times \left(\frac{1}{M} \times \frac{N}{M}\right)$   $\times (in)$ 

上記の(式25)及び(式26)に示すように補正項2(2)では、 技術文献A群及び技術文献B群の構成比と、各クラスタ内における技術 文献同士の混在比が同じであるほど類似率を高く設定する(1に近づける)ために、分子には「N/M又はn/mの小さい方」を配置し、分母には「N/M又はn/mの大きい方」を配置している。

この場合に、技術文献の混在比が小さい混在クラスタの影響を、類似率の算出結果に大きく反映させたくない場合には、補正項の指数くを く>1 に設定するとよい。

10 また、単純にクラスタ内における技術文献の混在比に応じて類似率を 増減させる要望がある場合には、 に = 1 に設定するとよい。

また、混在比が大きい混在クラスタの影響を類似率の算出結果に大き く反映させたくない要求がある場合には、0 < ζ < 1 に設定するとよ い。

15 以下に、類似率の計算に際して補正項2(2)を用いる場合の作用に ついて説明する。

補正項2(2)では、分子にA群とB群の技術文献数量の構成比又は各クラスタ内における技術文献同士の混在比のいずれが小さい方を配置し、分母にA群とB群の技術文献数量の構成比又は各クラスタ内におりる技術文献同士の混在比のいずれか大きい方を配置するようにしたので、A群とB群の技術文献数量の構成比と各クラスタ内における技術文献同士の混在比が同じであるほど類似率を高く算出する(1に近づける)ことが可能となる。また、A群とB群の技術文献数量の構成比と各クラスタ内における技術文献同士の混在比が異なるほど類似率を小さい値に算出することが可能となる。

また、A群とB群の技術文献数量の構成比と、各クラスタ内における 技術文献同士の混在比との比を算出しているので、類似率の算出範囲を 0≤類似率≤1 を保証することが可能となる。

更に、指数 ζ を ζ >1 に設定することによって、A群とB群の技

WO 2005/033972

10

15

術文献数量の比と、各クラスタ内における技術文献同士の混在比との比が小さい混在クラスタの影響を、類似率の算出結果に大きく反映させないようにすることが可能となる。

また、指数くを く=1 に設定することによって、単純にA群とB: 5 群の技術文献数量の構成比と、各クラスタ内における技術文献同士の混 在比との比に応じて類似率を増減させることが可能となる(単純混在比 比較)。

また、分子の指数を0< < < 1 に設定することによって、A群とB 群の技術文献数量の構成比と、各クラスタ内における技術文献同士の混 在比との比が大きい場合に類似率の算出結果に対する影響を少なぐす ることが可能となる。

補正項2(2)のみを考慮して他の補正項の作用を考慮しない場合であって(すなわち補正項1=1、補正項3=1とする)、単純混在比比較を行なう場合(すなわちく=1)に、技術文献群同士を比較する条件として、(式26)において条件1~4に設定した場合の類似率の試算結果を以下に示す。なお、算出結果は、図土4に、補正項2(2)を採用した場合の類似率算出例(補正項2(2)に条件1~4を代入した場合の計算結果)の図表として示す。

下式(式27)に、計算例26<u>1</u>(式26に条件1を代入した場合) 20 の計算結果を示す。

条件1では、第1の技術文献群(A群)の技術文献数量は6個、第2の技術文献群(B群)の技術文献数量も6個であるので、A群と群B群の技術文献数量の構成比は1対1である。

一方、条件1の場合に各混在クラスタ(クラスタ1及びクラスタ2) 25 に含まれる技術文献数は、第1の技術文献群(A群)の技術文献が2個、 第2の技術文献群(B群)の技術文献が1個であるので、混在比は2対 1である。

したがって、クラスタに含まれる技術文献の混在比による類似率の補 正の影響は、少なからず存在することが期待される。

5 下式 (式 2 8) に、計算例 2 6 = 2 (式 2 6 に条件 2 を代入した場合) の計算結果を示す。

下式(式29)に、計算例26-3(式26に条件3を代入した場合) の計算結果を示す。

条件3の場合には、条件2の場合とクラスタに含まれる技術文献の量の総和は同じであるが、混在クラスタ1に含まれる技術文献の混在比が、第1の技術文献群(A群)と第2の技術文献群(B群)の構成比と大きく異なる状況である。したがって類似率を算出する際に、混在クラスタ1に含まれる技術文献の混在比率の影響が条件2の場合ほどは生じないことが望ましい。

10

類似率(式 2 6,条件 3) = 
$$\frac{1}{2\sqrt{2\pi}} \sum_{\substack{0 \le 0 \le 0 \le 1}}^{2\sqrt{2\pi}} \left( 補正項1 \right) \times \left( 補正項2 \right) \times \left( 補正項3 \right) \times \delta \right)$$

$$= \frac{1}{4} \left\{ \frac{MIN\left(\frac{55}{104}, \frac{50}{20}\right)}{MAX\left(\frac{55}{104}, \frac{50}{20}\right)} + \frac{MIN\left(\frac{55}{104}, \frac{1}{2}\right)}{MAX\left(\frac{55}{104}, \frac{1}{2}\right)} \right\} = \frac{1}{4} \left\{ \frac{\frac{55}{104}}{\frac{50}{20}} + \frac{\frac{1}{2}}{\frac{55}{104}} \right\}$$

$$= \frac{1}{4} \left\{ \frac{1100}{5200} + \frac{104}{110} \right\} = \frac{1}{4} \times 1. \ 156 = 0. \ 289. (329)$$

上記の(式29)にて算出した類似率(式26に条件3を代入)=0.289 15 の値は、混在クラスタ1に含まれる技術文献の混在比が、第1の技術文献群(A群)と第2の技術文献群(B群)の構成比と異なることから、類似率は少なく補正される。

したがって、補正2(2)の演算処理を行なうことによって、混在ク

ラスタに含まれる技術文献の量が多い場合であっても、その技術文献の 混在比率に応じて類似率を補正することが可能となる。

下式(式30)に、計算例2.6-4(式2.6に条件4を代入した場合) の計算結果を示す。

5

類似率(式 2 6 ,条件 4 ) =  $\frac{1}{2\sqrt{2}} \sum_{\substack{0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0.5 < 0$ 

$$= \frac{1}{2} \frac{2^{\frac{3}{2}}}{2^{\frac{3}{2}}} \left[ (補正項1) \times \left\{ \frac{M + N \left( \frac{N}{M} - \frac{n}{m} \right)}{MAX \left( \frac{N}{M} - \frac{n}{m} \right)} \right\} \times (補正項3) \times \delta \right]$$

$$= \frac{1}{2} \int_{1}^{4} \left[ 1 \times \left\{ \frac{M + N \left( \frac{5}{1} + \frac{n}{M} - \frac{n}{m} \right)}{1 \times 4 \times \delta} \right\} \times \frac{1}{2} \times \frac{1}{2} \times \delta \right]$$

$$= \frac{1}{4} \sum_{j=2,3}^{4} \left[ 1 \times \left\{ \frac{M + N \left( \frac{3.5}{1.0.4} \cdot \frac{n}{m} \right)}{MA \times \left( \frac{5.5}{1.0.4} \cdot \frac{n}{m} \right)} \right\} \times 1 \times \delta \right]$$

$$= \frac{1}{4} \left\{ \frac{M + N \left( \frac{55}{104}, \frac{50}{2} \right)}{MAX \left( \frac{55}{104}, \frac{50}{2} \right)} + \frac{M + N \left( \frac{55}{104}, \frac{1}{20} \right)}{MAX \left( \frac{55}{104}, \frac{1}{20} \right)} \right\} = \frac{1}{4} \left\{ \frac{\frac{55}{104}}{\frac{50}{2}} + \frac{\frac{1}{20}}{\frac{55}{104}} \right\}$$

$$= \frac{1}{4} \left\{ \frac{110}{5200} + \frac{104}{1100} \right\} = \frac{1}{4} \times 0. \quad 116 = 0. \quad 029 \quad ... (330)$$

上記の(式30)にて算出した類似率(式26に条件4を代入した場) 6)=0.029の値は、クラスタ1及びクラスタ2に含まれる技術文献の 混在比が極端に不均等であるとともに、混在クラスタ1及び混在クラスタ2の混在比が第1の技術文献群(A群)と第2の技術文献群(B群)の技術文献数量の構成比と大きく異なるので、類似率が少なく補正される。

15

図14に、補正項2(2)を採用した場合の類似率算出例(補正項2 (2)に条件1~4を代入した場合の計算結果)の図表を示す。 条件1、条件2における混在クラスタ1及び混在ウラスタ2。並びに条件3における混在クラスタ2は、図9に示すように技術文献がよく混ざ

20

25

35

っている状態であるといえる例(混在クラスタにおける技術文献の混在 比が、第1の技術文献群と、第2の技術文献群に含まれる技術文献の数 量の比に近い場合)である。この場合には、補正項の値を割合に大きく、 算出し、類似率の値を大きくする効果がある。

- 5 逆に、条件3の混在クラスタ1及び条件4の各混在クラスタは、技術 文献がよく混ざっていない状態であるといえる(混在クラスタにおける 技術文献の混在比が、第1の技術文献群と、第2の技術文献群に含まれ る技術文献の数量の比と大きく異なる場合といえる)ので、補正項の値 を小さく算出し、類似率を小さい値に算出する効果がある。
- 10 したがって(式4)に示したような、補正項1(1)と組み合わせて 類似率を算出することによって、技術文献群同士がどの程度技術的に関 連があるかを示す類似率の算出制度を向上させることが可能となる。

図15に、補正項1(1)及び補正項2(2)を採用した場合の類似率算出例(補正項1(1)及び補正項2(2)に条件1~4を代入した場合の計算結果)の図表を示す。

同図に示すように、補正項1 (1)及び補正項2 (2)を用いた計算式に条件1を代入すると、クラスタ内に含まれる技術文献数量と混在比率に応じた類似率を算出するので、条件1を代入した場合の類似率=0.25の値は、(式1)に条件1を代入した場合(補正項なしの場合)の類似率=0.5の値より小さいが、かなり期待した値に近く、技術文献群同士の技術の類似性をよく表していると言える。

また、補正項1 (1) 及び補正項2 (2) を用いた計算式に条件2を 代入すると、クラスタ内に含まれる技術文献数量と混在比率に応じた類。 似率を算出するので、類似率は(式1)に条件2を代入した場合(補正 なしの場合)の類似率=0.5 から、補正項1及び補正項2 (2) を用い て条件2を代入した場合の類似率=0.909 に補正され、かなり期待した 類似率の値に近く、技術文献同士の類似性をよく表していると言える。 このように補正項1及び補正項2 (2) を用いて類似率を算出することによって、技術文献数の多いクラスタ1について重み付けをすること

が可能となる。

また、補正項1(1)及び補正項2(2)を用いた計算式に条件3を 代入すると、クラスタ内に含まれる技術文献数量と混在比率に応じた類 似率を算出するので、条件2の場合と比較してクラスタ内に含まれる技 術文献数量の総和は同じだが、混在クラスタ1の技術文献数量のみが特 に多いわけではなく、かつ、クラスタ1内の技術文献の混在比率が第1 の技術文献群(A群)と第2の技術文献群(B群)の技術文献数量の比 率とも異なる場合には、クラスタ1の存在を特に重視しないようにすることが可能となる。

ここで算出される類似率は、(式1): に条件3を代入した場合、(補正なしの場合)の類似率=0.5から、補正項1及び補正項2(2)を用いて条件3を代入した場合の類似率=0.111に補正され、かなり期待した値に近く、技術文献群同士の類似性を表していると言える。

また、補正項1 (1)及び補正項2 (2)を用いた計算式に条件4を 代入すると、クラスタ内に含まれる技術文献数量と混在比率に応じた類 似率を算出するので、条件2の場合と比較してクラスタ内に含まれる技 術文献数量の総和は同じだが、混在クラスタ1や混在クラスター2が特に 大きいわけではなく、技術文献の混ざり具合がさらに極端な場合で、混 在クラスタ内における技術文献の混在比が、A群とB群の技術文献数の 20 比と大きく異なるので、類似率に反映する影響が小さくなっている。

ここで算出される類似率は、(式1)に条件4を代入した場合 (補正なしの場合)の類似率=0.5から、補正項1及び補正項2(2)を用いて条件4を代入した場合の類似率=0.019に補正され、かなり期待した値に近く、技術文献同士の類似性をよく表していると言える。

25 応用型4:補正項2(3)の算出例

以下に、混在クラスタ内における技術文献の期待値差に基づく補正について説明する。

あるクラスタ内に含まれる第1の技術文献群 (A群) の技術文献の数 量Mと、第2の技術文献群 (B群) の技術文献の数量Nとが、A群とB 群から無作為に抽出した際の期待値 (M/(M+N)) に近いほど、良く混ざっていると考えるのは自然である。(前記(式9)に示した確率 比、又は(式25)に示した混在比と並ぶ第3の混ざり具合の定義である。)

5 そこで本発明では、第1の技術文献群(A群)と第2の技術文献群(B群)とを混合した技術文献群の中から、第1の技術文献群(A群)の技術文献群(A群)の技術文献教(m+n)を乗算して第1の技術文献群(A群)の技術文献を取り出す期待値を算出し、その期待値と混合クラスタに含まれる第1の技術文献群(A群)の技術文献群(A群)の技術文献数mとの差を期待値差(下(式31)参照)として算出し、この差が小さいほど(0に近いほど)類似率が高くなるように補正する演算を行なう。

以下の(式31)に期待値差の算出例を示す。

期待値差=
$$(m+n)\left(\frac{M}{M+N}\right)-m$$

$$=\frac{|mM+nM-mM-mN|}{M+N}$$

$$=\frac{|nM-mM|}{M+N}...(式31)$$

15

図16に、上記の(式31)に条件1~4を代入した場合の期待値差 の算出例を示す。

上記の(式31)による計算結果からもわかるとおり、あるクラスタ 20 内に含まれるA群の技術文献の数量と、B群の技術文献の数量とが、A 群とB群から無作為に抽出した際の期待値に近いほど、そのクラスタを 重要視して類似率を補正する場合には、図16に示す期待値差を負の数 にして指数部分に置くとよい。

負の値にした期待値差を指数部分に配置することによって、混在クラ

スタに期待値どおりの技術文献が存在する場合には、期待値差 = 0 となり、指数 = 0 の場合には、補正項の値を 1 と算出することが可能となるからである。ところが、期待値のままだと混ざり具合だけでなく所定の混在クラスタの大きさにも依存してしまうため、期待値差をクラスタに含まれる技術文献数で除算するとよい。

このようにして求めた補正項2(3)の実施例を以下に示す。

補正項2 (3) =  $\xi^{-\frac{|nM-mN|}{(M+N)(m+n)}}$ ...(式32)

10 但し、

15

25

ξ:任意定数であって、ξ>1 とする。

類似率を小さく補正することが可能となる。

上記(式32)のように補正項2を算出することによって、例えば、 クラスタの大きさが100で期待値差が10の時とクラスタの大きさ が10で期待値差が1の時の補正値を同じにすることが可能となる。 なお、ξの値を大きく設定するほど期待値差に対して敏感に反応して

図17に、 $\xi=1$ 0とした場合において、(式32) に条件 $1\sim4$ を代入した場合の類似率算出例を示す。

20 図18に、補正項1(1)及び補正項2(3)を採用した場合の類似率算出例(補正項1(1)及び補正項2(3)に条件-1~4を代入した場合の計算結果)の図表を示す。

同図に示すように、補正項1 (1)及び補正項2 (3)を用いた計算式に条件1を代入すると、クラスタ内に含まれる技術文献数量と期待値差に応じた類似率を算出する(あるクラスタ内に含まれる第1の技術文献群(A群)の技術文献の数量と、第2の技術文献群(B群)の技術文献の数量とが、A群とB群から無作為に抽出した際の期待値に近い程類似率を大きく算出する補正を行なう)ので、補正項1及び補正項2(3)

を用いて条件 1 を代入した場合の類似率 = 0.340 は、(式 1) に条件 1 を 代入した場合 (補正なしの場合) の類似率 = 0.5 の値に近く、期待した 値に近い値を算出することが可能となっている。

条件2の場合には、混在クラスタ1は、クラスタ2~4と比べると混在クラスタに含まれる技術文献数が大きい上に、期待値差も少ないので混在クラスタ1に含まれる技術文献の構成の影響を重視すべきである。補正項1(1)及び補正項2(3)を用いた計算式に条件2を代入すると、クラスタ内に含まれる技術文献数量と期待値差に応じた類似率を算出する(あるクラスタ内に含まれる第1の技術文献群(A群)の技術文献の数量と、第2の技術文献群(B群)の技術文献の数量とが、A群とB群から無作為に抽出した際の期待値に近い程類似率を大きく算出する補正を行なう)ので、補正項1及び補正項2(3)を用いて条件2を代入した場合の類似率=0.935は、(式1)に条件1を代入した場合(補正なしの場合)の類似率=0.5の値より大きく補正されており、この値は期待した値に近い値となる。

条件3の場合には、前記の条件2の場合と比較してクラスタに含まれる技術文献数量の総和は同じだが、混在クラスタ1だけが特に大きい訳ではないのでクラスタ1を特に重視しないはずである。また、混在クラスタ1に含まれる技術文献は、第1の技術文献群(A群)と第2の技術文献群(B群)から無作為に抽出した際の期待値と大きく異なるので、混在クラスタ1の期待値差の大きさに引っ張られ類似率は小さく算出されるはずである。

20

補正項1(1)及び補正項2(3)を用いた計算式に条件3を代入すると、クラスタ内に含まれる技術文献数量と期待値差に応じた類似率を算出する(あるクラスタ内に含まれる第1の技術文献群(A群)の技術文献の数量と、第2の技術文献群(B群)の技術文献の数量とが、A群とB群から無作為に抽出した際の期待値に近い程類似率を大きく算出する補正を行なう)ので、補正項1及び補正項2(3)を用いて条件3を代入した場合に、類似率=0.207と算出される。この類似率の値も期

待した値に近い値である。

条件4の場合には、条件3と比べてクラスタ内に含まれる技術文献数量の総和は同じだが、混在クラスタ1や混在クラスタ2に含まれる技術文献数量が特に大きい訳ではなく、混ざり具合がさらに極端な場合なので、混在クラスタ1の重み付けに引っ張られないことが望ましい。 補正項1 (1) 及び補正項2 (3) を用いた計算式に条件4を代入すると、クラスタ内に含まれる技術文献数量と期待値差に応じた類似率を算出する(あるクラスタ内に含まれる第1の技術文献群(A群)の技術文献の数量と、第2の技術文献群(B群)の技術文献の数量とが、A群 とB群から無作為に抽出した際の期待値に近い程類似率を大きく算出する補正を行なう)ので、補正項1及び補正項2 (3) を用いて条件4を代入した場合には、類似率=0.146と算出される。この類似率の値も、期待した値に近い値である。

## . 15 産業上の利用可能性

20

25

本発明によれば、特許文献又は技報等の技術文献から構成される第1の技術文献群と第2の技術文献群との技術的な類似性を判断するための指標を算出する類似率算出装置であって、比較対象となる第1の技術文献群及び第2の技術文献群を入力する技術文献群入力手段と、第1の技術文献群及び第2の技術文献群に含まれる技術文献について前記入力した技術情報を含む技術文献を検索して該検索した技術文献をそれぞれの技術情報を含む技術文献を検索して該検索した技術文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、前記クラスタ分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数との比を類似率として算出する類似率算出手段と、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する出力手段とを備えたので、その分解した全クラスタ数と混在クラスタ数の比に基づいて、技術文献群に記載されている技術内容の類似性を示す指標を簡便に算出することが可能となる。

20

25

また本発明によれば、類似率算出手段に各混在クラスタに含まれる技術文献の量に応じた値を取る第1の補正値と、各混在クラスタに含まれる第1の技術文献群の技術文献と第2の技術文献群の技術文献との混ざり具合に応じた値を取る第2の補正値とを乗算したものを、各混在クラスタについて総和を算出して、全クラスタ数で除算して類似率を算出する機能を設けたので、補正項1の存在により混在クラスタに含まれる技術文献の量に応じて重要度が高いことを意味付ける補正が可能となるとともに、補正項2の存在により混在クラスタに含まれる技術文献の割合が所定の量に近い程、重要なクラスタであるとして、類似率が高い関値を示すように重い重み付けをして、類似率の算出結果を、より人の感覚に合うように補正することが可能となる。

従って、補正項1及び補正項2を用いて類似率を算出することによって、技術文献数量の多い混在クラスタを重要視して類似率を補正するとともに、技術文献の混ざり具合が不均一な場合には、類似率を小さい値に補正することが可能となる。

また本発明によれば、類似率算出手段に個々のクラスタ内の技術文献数の α 乗 (但し、0 < α) に比例した補正値を各混在クラスタについて 総和を算出し、全クラスタ数で除算して類似率を算出する機能を設けたので、クラスタ内の技術文献数が多いほど重要なクラスタであるとする ような類似率を算出することが可能となる。

また本発明によれば、類似率算出手段に個々のクラスタ内の技術文献数の $\alpha$ 乗(但し、 $0 < \alpha$ )を、全クラスタ数等の規格化因子で除算して類似率を算出する機能を備えたので、 $0 \le$ 類似率 $\le 1$  を保証することが可能となる。また、規格化因子として全クラスタ内の技術文献数の平均値を配置したので、全クラスタ内の技術文献数の平均値を基準として 技術文献の量の多少を算出することが可能となる。

また本発明によれば類似率算出手段に、第1の技術文献群の中からm。個、第2の技術文献群の中からn個の技術文献を取り出す確率のγ乗(但し、0 < γ)に比例した補正値を各混在クラスタについて総和を算出

15

25

し、全クラスタ数で除算して類似率を算出する機能を設けた。すなわち 、類似率算出手段に(A群の中からm個、B群の中からn個の技術文献 を取り出す組合せの数)/(A群とB群とを混ぜ合わせた中からmin 個の技術文献を取り出す組合せ数)を分子に配置した演算を行なう機能 を備えたので、混在クラスタに含まれるA群及びB群の技術文献数の偏 り(作為性)に応じて、偏り大の場合は小さい補正値に、偏り小の場合 は大きい補正値に類似率を補正することが可能となる。また、規格化因 子として、第1の技術文献群の中からm個、第2の技術文献群の中から n個の技術文献を取り出す確率の最大値のγ乗(但し、0 < γ)を配置 したので、類似率の算出範囲として0≤類似率≤1 を保証することが 可能となる。

また本発明によれば類似率算出手段に、第1の技術文献群に含まれる 技術文献数Mと第2の技術文献群に含まれる技術文献数Nとの構成比、 N/Mと、クラスタ分解した結果得られた混在クラスタに含まれる第1-の技術文献群の技術文献数mと第2の技術文献群の技術文献数nの混 在比、n/mとについて、更に構成比と混在比との比を取ったもののζ 乗(但し、0< ζ)に比例した補正値を各混在クラスタについて総和を 算出し、全クラスタ数で除算して類似率を算出する機能を備えたので、 A群とB群の技術文献数量の構成比と各クラスタ内における技術文献 20 同士の混在比が同じであるほど類似率を高く算出する(1に近づける) ことが可能となる。

また、構成比と混在比との比の指数でを く>1 に設定することに よって、A群とB群の技術文献数量の比と、各クラスタ内における技術 文献同士の混在比との比が小さい混在クラスタの影響を、類似率の算出 結果に大きく反映させないようにすることが可能となる。

また、指数くを く=1 に設定することによって、単純にA群とB 群の技術文献数量の構成比と、各クラスタ内における技術文献同士の混 在比との比に応じて類似率を増減させることが可能となる。

・また、分子の指数を0<<<<br/>
くく1<br/>
に設定することによって、A群とB

群の技術文献数量の構成比と、各クラスタ内における技術文献同士の混合 在比との比が大きい場合に類似率の算出結果に対する影響を少なくする ることが可能となる。

また本発明によれば類似率算出手段に、第1の技術文献群と第2の技術文献群とを混合した技術文献群の中から第1の技術文献群の技術文献群の技術文献を取り出す確率に前記クラスタ分解した混在クラスタに含まれる技術文献数を乗算して第1の技術文献群の技術文献を取り出す期待値を算出し、前記期待値と混合クラスタに含まれる第1の技術文献群の技術、文献数との差を期待値差として算出し、その期待値差を任意定数を(但定し、1
し、1
も)の負の指数とした補正値を、各混在クラスタについて総和を算出し、全クラスタ数で除算して類似率と算出するようにしたので、その値の設定に応じて期待値差に対する類似率の算出結果を敏感に反応させる補正を行なうことが可能となる。

また本発明によれば類似率算出手段に、第1の技術文献群と第2の技術文献群とを混合した技術文献群の中から第1の技術文献群の技術文献群の技術文献群の技術文献群の技術文献教を乗算して第1の技術文献群の技術文献を取り出す期待値を算出し、前記期待値と混合クラスタに含まれる第1の技術文献群の技術文献数との差を期待値差として算出し、その期待値差を混在クラスタに含まれる技術文献数で除算したものを、任意定数を(但し、1<を)の負の指数とした補正値とし、これを各混在シラスタについて総和を算出し、更に全クラスタ数で除算して類似率と算出するようにしたので、をの値の設定に応じて期待値差に対する類似率の算出結果を敏感に反応させる補正を行なうことが可能となる。

20

## 請求の範囲

1.特許文献又は技報等の技術文献から構成される第1の技術文献群と第2の技術文献群との、技術的な類似性を判断するための指標を算出する類似率算出装置であって、

比較対象となる第1の技術文献群及び第2の技術文献群を入力する 技術文献群入力手段と、

キーワードやIPCなどの技術情報を入力する技術情報入力手段と、 第1の技術文献群及び第2の技術文献群に含まれる技術文献につい て、前記入力した技術情報を含む技術文献を検索して、該検索した技術 文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、 前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献 群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数との 比を類似率として算出する類似率算出手段と、

15 前記算出した類似率を記録手段、表示手段、又は通信手段に出力する 出力手段と、

を備えたことを特徴とする類似率算出装置。

2. 特許文献又は技報等の技術文献から構成される第1の技術文献群と 第2の技術文献群との、技術的な類似性を判断するための指標を算出す る類似率算出装置であって、

比較対象となる第1の技術文献群及び第2の技術文献群をズガする 技術文献群入力手段と、

キーワードやIPCなどの技術情報を入力する技術情報入力手段と、 第1の技術文献群及び第2の技術文献群に含まれる技術文献につい 25 て、前記入力した技術情報を含む技術文献を検索して、該検索した技術 文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、

前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献 群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算 出するとともに、

各混在クラスタに含まれる技術文献の量に応じた値を取る第1の補 正値と、各混在クラスタに含まれる第1の技術文献群の技術文献と第2 の技術文献群の技術文献との混ざり具合に応じた値を取る第2の補正 値とを乗算したものを各混在クラスタについて総和を算出し、前記算出

前記算出した類似率を記録手段、表示手段、又は通信手段に出力する出力手段と、

した全クラスタ数で除算して類似率を算出する類似率算出手段と、、、

を備えたことを特徴とする類似率算出装置。

10 3. 特許文献又は技報等の技術文献から構成される第1の技術文献群と 第2の技術文献群との、技術的な類似性を判断するための指標を算出す る類似率算出装置であって、

比較対象となる第1の技術文献群及び第2の技術文献群を入力する。 技術文献群入力手段と、

15 キーワードや I P C などの技術情報を入力する技術情報入力手段と、 第1の技術文献群及び第2の技術文献群に含まれる技術文献につい て、前記入力した技術情報を含む技術文献を検索して、該検索した技術 文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、

前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献 20 群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算 出するとともに、

個々のクラスタ内の技術文献数の α 乗 (但し、0 < α) に比例した補 正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ 数で除算して類似率を算出する類似率算出手段と、

25 前記算出した類似率を記録手段、表示手段、又は通信手段に出力する 出力手段と、

を備えたことを特徴とする類似率算出装置。

4. 特許文献又は技報等の技術文献から構成される第1の技術文献群と第2の技術文献群との、技術的な類似性を判断するための指標を算出す

10.

る類似率算出装置であって、

比較対象となる第1の技術文献群及び第2の技術文献群を入力する 技術文献群入力手段と、

キーワードやIPCなどの技術情報を入力する技術情報入力手段と、 第1の技術文献群及び第2の技術文献群に含まれる技術文献につい て、前記入力した技術情報を含む技術文献を検索して、該検索した技術 文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、 前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献 群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算 出するとともに、

個々のクラスタ内の技術文献数のα乗(但し、0 < α)を規格化因子で除算した補正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する類似率算出手段と、

前記算出した類似率を記録手段、表示手段、又は通信手段に出力する 15 出力手段と、

を備えたことを特徴とする類似率算出装置。

- 5. 請求の範囲4に記載の類似率算出装置における前記規格化因子は、 全クラスタ内の技術文献数の平均値であることを特徴とする類似率算 出装置。
- 20 6.特許文献又は技報等の技術文献から構成される第1の技術文献群と 第2の技術文献群との、技術的な類似性を判断するための指標を算出す る類似率算出装置であって、

比較対象となる第1の技術文献群及び第2の技術文献群を入力する 技術文献群入力手段と、

25 キーワードやIPCなどの技術情報を入力する技術情報入力手段と、 第1の技術文献群及び第2の技術文献群に含まれる技術文献につい て、前記入力した技術情報を含む技術文献を検索して、該検索した技術 文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、 前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献

群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算 出するとともに、

前記クラスタ分解した結果得られた混在クラスタに含まれる第1の 技術文献群及び第2の技術文献群の技術文献数の確率に応じて補正す るために、第1の技術文献群の中からm個、第2の技術文献群の中から n個の技術文献を取り出す確率のγ乗(但し、0 < γ)に比例した補正 値を各混在クラスタについて総和を算出し、前記算出した全クラズタ数 で除算して類似率を算出する類似率算出手段と、

前記算出した類似率を記録手段、表示手段、又は通信手段に出力する 10 出力手段と、

を備えたことを特徴とする類似率算出装置。

7. 特許文献又は技報等の技術文献から構成される第1の技術文献群と 第2の技術文献群との、技術的な類似性を判断するための指標を算出す る類似率算出装置であって、

15 比較対象となる第1の技術文献群及び第2の技術文献群を入力する 技術文献群入力手段と、

キーワードやIPCなどの技術情報を入力する技術情報入力手段と、 第1の技術文献群及び第2の技術文献群に含まれる技術文献につい て、前記入力した技術情報を含む技術文献を検索して、該検索した技術 文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、 前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献 群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算 出するとともに、

前記クラスタ分解した結果得られた混在クラスタに含まれる第1の 技術文献群及び第2の技術文献群の技術文献数の確率に応じて補正するために、第1の技術文献群の中からm個、第2の技術文献群の中から n個の技術文献を取り出す確率のγ乗(但し、0 < γ)を規格化因子で 除算した補正値を各混在クラスタについて総和を算出し、前記算出した 全クラスタ数で除算して類似率を算出する類似率算出手段と、 前記算出した類似率を記録手段、表示手段、又は通信手段に出力する出力手段と、

を備えたことを特徴とする類似率算出装置。

10

25

- 8. 請求の範囲7に記載の類似率算出装置における前記規格化因子は、
- 5 第1の技術文献群の中からm個、第2の技術文献群の中からm個の技術 文献を取り出す確率の最大値のγ乗(但し、0 < γ)であることを特徴とする類似率算出装置。
  - 9. 特許文献又は技報等の技術文献から構成される第1の技術文献群と第2の技術文献群との、技術的な類似性を判断するための指標を算出する類似率算出装置であって、

比較対象となる第1の技術文献群及び第2の技術文献群を入力する 技術文献群入力手段と、

キーワードやIPCなどの技術情報を入力する技術情報入力手段と、 第1の技術文献群及び第2の技術文献群に含まれる技術文献につい て、前記入力した技術情報を含む技術文献を検索して、該検索した技術 文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、

前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献 群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算 出するとともに、

20 第1の技術文献群に含まれる技術文献数Mと第2の技術文献群に含まれる技術文献数Nとの構成比、N/Mと、

前記クラスタ分解した結果得られた混在クラスタに含まれる第1の 技術文献群の技術文献数mと第2の技術文献群の技術文献数nの混在 比、n/mとについて、更に構成比と混在比との比を取ったもののな乗 (但し、0 < く)に比例した補正値を各混在クラスタについて総和を算 出し、前記算出した全クラスタ数で除算して類似率を算出する類似率算 出手段と、

前記算出した類似率を記録手段、表示手段、又は通信手段に出力する出力手段と、

<sup>--</sup> 15

を備えたことを特徴とする類似率算出装置。

- 10.特許文献又は技報等の技術文献から構成される第1の技術文献群と第2の技術文献群との、技術的な類似性を判断するための指標を算出する類似率算出装置であって、
- 5 比較対象となる第1の技術文献群及び第2の技術文献群を入力する 技術文献群入力手段と、

キーワードやIPCなどの技術情報を入力する技術情報入力手段と、 第1の技術文献群及び第2の技術文献群に含まれる技術文献につい て、前記入力した技術情報を含む技術文献を検索して、該検索した技術 文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、

前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献 群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算 出するとともに、

第1の技術文献群と第2の技術文献群とを混合した技術文献群の中から、第1の技術文献群の技術文献を取り出す確率に、前記クラスタ分解した混在クラスタに含まれる技術文献数を乗算して第1の技術文献群の技術文献を取り出す期待値を算出し、

前記期待値と混合クラスタに含まれる第1の技術文献群の技術文献 数との差を期待値差として算出し、

20 その期待値差を任意定数 £ (但し、1 < ξ) の負の指数とした補正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する類似率算出手段と、

前記算出した類似率を記録手段、表示手段、又は通信手段に出力する出力手段と、

25 を備えたことを特徴とする類似率算出装置。

11.特許文献又は技報等の技術文献から構成される第1の技術文献群と第2の技術文献群との、技術的な類似性を判断するための指標を算出する類似率算出装置であって、

比較対象となる第1の技術文献群及び第2の技術文献群を入力する

技術文献群入力手段と、

キーワードやIPCなどの技術情報を入力する技術情報入力手段と、 第1の技術文献群及び第2の技術文献群に含まれる技術文献について、前記入力した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解するクラスタ分解手段と、 前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献 群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、

第1の技術文献群と第2の技術文献群とを混合した技術文献群の中 10 から、第1の技術文献群の技術文献を取り出す確率に、前記クラスタ分 解した混在クラスタに含まれる技術文献数を乗算して第1の技術文献 群の技術文献を取り出す期待値を算出し、

前記期待値と混合クラスタに含まれる第1の技術文献群の技術文献 数との差を期待値差として算出し、。

15 その期待値差を混在クラスタに含まれる技術文献数で除算したもの。 を、任意定数 ξ (但し、1 < ξ) の負の指数とした補正値とし、これを 各混在クラスタについて総和を算出し、更に前記算出した全クラスタ数 で除算して類似率を算出する類似率算出手段と、

前記算出した類似率を記録手段、表示手段、又は通信手段に出力する 20 出力手段と、

を備えたことを特徴とする類似率算出装置。

12.技術文献群を入力する技術文献群入力手段と、キーワードなどの技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と25 を算出して類似率を算出する類似率算出手段と、算出した類似率を出力する出力手段と、前記技術文献群入力手段と技術情報入力手段とクラスタ分解手段と類似率算出手段と出力手段とを制御をすることが可能な情報処理手段とを備えた類似率算出装置の情報処理手段にて動作し、技術文献群同士の技術的な類似性を判断するための指標を算出する類似

15

率算出プログラムであって、

前記情報処理手段に、

前記技術文献群入力手段が、比較対象となる第1の技術文献群及び第 2の技術文献群を入力する機能と、

前記技術情報入力手段が、キーワードやIPCなどの技術情報を入力する機能と、

前記クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に 含まれる技術文献について、前記入力した技術情報を含む技術文献を検 索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する機能と、

前記類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、前記クラスタ分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数との比を類似率として算出する機能と、前記出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する機能と、

を実現させることを特徴とする類似率算出プログラム。

13.技術文献群を入力する技術文献群入力手段と、キーワードなどの 技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にク ラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と を算出して類似率を算出する類似率算出手段と、算出した類似率を出力・ する出力手段と、前記技術文献群入力手段と技術情報入力手段とクラス タ分解手段と類似率算出手段と出力手段とを制御をすることが可能な 情報処理手段とを備えた類似率算出装置の情報処理手段にて動作し、技 術文献群同士の技術的な類似性を判断するための指標を算出する類似 率算出プログラムであって、

前記情報処理手段に、

前記技術文献群入力手段が、比較対象となる第1の技術文献群及び第

. :

2の技術文献群を入力する機能と、

前記技術情報入力手段が、キーワードやIP-Cなどの技術情報を入力する機能と、

前記クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に 含まれる技術文献について、前記入力した技術情報を含む技術文献を検 索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解す る機能と、

前記類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、各混在クラスタに含まれる技術文献の量に応じた値を取る第1の補正値と、各混在クラスタに含まれる第1の技術文献群の技術文献と第2の技術文献群の技術文献との混ざり具合に応じた値を取る第2の補正値とを乗算したものを各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する機能と、

前記出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する機能と、

を実現させることを特徴とする類似率算出プログラム。

14.技術文献群を入力する技術文献群入力手段と、キーワードなどの 技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクーラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と を算出して類似率を算出する類似率算出手段と、算出した類似率を出力する出力手段と、前記技術文献群入力手段と技術情報入力手段とクラスタ分解手段と類似率算出手段と出力手段とを制御をすることが可能な 情報処理手段とを備えた類似率算出装置の情報処理手段にて動作し、技術文献群同士の技術的な類似性を判断するための指標を算出する類似率算出プログラムであって、

前記情報処理手段に、

- - .

前記技術文献群入力手段が、比較対象となる第1の技術文献群及び第

2の技術文献群を入力する機能と、

前記技術情報入力手段が、キーワードやIPCなどの技術情報を入力する機能と、

前記クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に 含まれる技術文献について、前記入力した技術情報を含む技術文献を検 索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する機能と、

前記類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、個々のクラスタ内の技術文献数の α乗(但し、0 < α)に比例した補正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する機能と、

前記出力手段が、前記算出した類似率を記録手段、表示手段、又は通 15 信手段に出力する機能と、

を実現させることを特徴とする類似率算出プログラム。-

15.技術文献群を入力する技術文献群入力手段と、キーワードなどの技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と20 を算出して類似率を算出する類似率算出手段と、第出した類似率を出力する出力手段と、前記技術文献群入力手段と技術情報入力手段とクラスタ分解手段と類似率算出手段と出力手段とを制御をすることが可能な情報処理手段とを備えた類似率算出装置の情報処理手段にて動作し、技術文献群同士の技術的な類似性を判断するための指標を算出する類似率算出プログラムであって、

前記情報処理手段に、

前記技術文献群入力手段が、比較対象となる第1の技術文献群及び第 2の技術文献群を入力する機能と、

前記技術情報入力手段が、キーワードやIPCなどの技術情報を入力

する機能と、

前記クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に 含まれる技術文献について、前記入力した技術情報を含む技術文献を検 索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解す る機能と、

前記類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、個々のクラスタ内の技術文献数の α乗(但し、0 < α)を規格化因子で除算した補正値を各混在クラスタについて総和を算出し、類似率を算出する機能と、

前記出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する機能と、

を実現させることを特徴とする類似率算出プログラム。

- 16.請求の範囲15に記載の類似率算出プログラムにおいて、
- 15 前記情報処理手段に、

前記類似率算出手段が、前記規格化因子として、全クラスタ内の技術文献数の平均値を用いる機能を実現させることを特徴とする類似率算出プログラム。

17.技術文献群を入力する技術文献群入力手段と、キーワードなどの 技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にク ラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と を算出して類似率を算出する類似率算出手段と、算出した類似率を出力 する出力手段と、前記技術文献群入力手段と技術情報入力手段とクラス タ分解手段と類似率算出手段と出力手段とを制御をすることが可能な 情報処理手段とを備えた類似率算出装置の情報処理手段にて動作し、技 術文献群同士の技術的な類似性を判断するための指標を算出する類似 率算出プログラムであって、

前記情報処理手段に、

前記技術文献群入力手段が、比較対象となる第1の技術文献群及び第

2の技術文献群を入力する機能と、

10

.15

前記技術情報入力手段が、キーワードや I-P-C などの技術情報を入力する機能と、

前記クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に 含まれる技術文献について、前記入力した技術情報を含む技術文献を検 索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解す る機能と、

前記類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、前記クラスタ分解した結果得られた混在クラスタに含まれる第1の技術文献群及び第2の技術文献群の技術文献群の中から加個、第2の技術文献群の中から加個の技術文献を取り出す確率の次乗(但し、0<γ)に比例した補正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する機能と

前記出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する機能と、

を実現させることを特徴とする類似率算出プログラム。

20 18.技術文献群を入力する技術文献群入力手段と、キーワードなどの 技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にク ラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と を算出して類似率を算出する類似率算出手段と、算出した類似率を出力 する出力手段と、前記技術文献群入力手段と技術情報入力手段とクラス タ分解手段と類似率算出手段と出力手段とを制御をすることが可能な 情報処理手段とを備えた類似率算出装置の情報処理手段にて動作し、技 術文献群同士の技術的な類似性を判断するための指標を算出する類似 率算出プログラムであって、

前記情報処理手段に、

出する機能と、

25

前記技術文献群入力手段が、比較対象となる第1の技術文献群及び第 2の技術文献群を入力する機能と、

前記技術情報入力手段が、キーワードやIPCなどの技術情報を入力する機能と、

5 前記クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に 含まれる技術文献について、前記入力した技術情報を含む技術文献を検 索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解す る機能と、

前記類似率算出手段が、前記クラスタ分解した結果得られた全クラス 10 夕数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含 む混在クラスタ数を算出するとともに、前記クラスタ分解した結果得ら れた混在クラスタに含まれる第1の技術文献群及び第2の技術文献群 の技術文献数の確率に応じて補正するために、第1の技術文献群の中から らm個、第2の技術文献群の中からn個の技術文献を取り出す確率の 乗(但し、0 < γ)を規格化因子で除算した補正値を各混在クラスタに ついて総和を算出し、前記算出した全クラスタ数で除算して類似率を算

前記出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する機能と、

20 を実現させることを特徴とする類似率算出プログラム。

19. 請求の範囲18に記載の類似率算出プログラムにおいて、前記情報処理手段に、

前記類似率算出手段が、前記規格化因子として、第1の技術文献群の中からm個、第2の技術文献群の中からm個の技術文献を取り出す確率の最大値のγ乗(但し、0 < γ)を用いる機能を実現させることを特徴。とする類似率算出プログラム。

20.技術文献群を入力する技術文献群入力手段と、キーワードなどの技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と

を算出して類似率を算出する類似率算出手段と、算出した類似率を出力する出力手段と、前記技術文献群入力手段と技術情報入力手段とクラスタ分解手段と類似率算出手段と出力手段とを制御をすることが可能な情報処理手段とを備えた類似率算出装置の情報処理手段にて動作し、技術文献群同士の技術的な類似性を判断するための指標を算出する類似率算出プログラムであって、

前記情報処理手段に、

前記技術文献群入力手段が、比較対象となる第1の技術文献群及び第2の技術文献群を入力する機能と、

10 前記技術情報入力手段が、キーワードや I P C などの技術情報を入力する機能と、

前記クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に 含まれる技術文献について、前記入力した技術情報を含む技術文献を検 索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解す る機能と、

前記類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、第1の技術文献群に含まれる技術文献数Mと第2の技術文献群に含まれる技術文献数Nとの構成比、N20 /Mと、前記クラスタ分解した結果得られた混在クラスタに含まれる第1の技術文献群の技術文献数mと第2の技術文献群の技術文献数nの混在比、n/mとについて、更に構成比と混在比との比を取ったもののな乗(但し、0<ζ)に比例した補正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する機能25 と、

前記出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する機能と、

を実現させることを特徴とする類似率算出プログラム。

21.技術文献群を入力する技術文献群入力手段と、ギーワードなどの

20

技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数とを算出して類似率を算出する類似率算出手段と、算出した類似率を出力する出力手段と、前記技術文献群入力手段と技術情報入力手段とクラスタ分解手段と類似率算出手段と出力手段とを制御をすることが可能な情報処理手段とを備えた類似率算出装置の情報処理手段にて動作し、技術文献群同士の技術的な類似性を判断するための指標を算出する類似率算出プログラムであって、

前記情報処理手段に、

10 前記技術文献群入力手段が、比較対象となる第1の技術文献群及び第 2の技術文献群を入力する機能と、

前記技術情報入力手段が、キーワードやIPCなどの技術情報を入力する機能と、

前記クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に 含まれる技術文献について、前記入力した技術情報を含む技術文献を検 索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解す る機能と、

前記類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、

第1の技術文献群と第2の技術文献群とを混合した技術文献群の中から、第1の技術文献群の技術文献を取り出す確率に、前記クラスタ分解した混在クラスタに含まれる技術文献数を乗算して第1の技術文献 群の技術文献を取り出す期待値を算出し、

25 前記期待値と混合クラスタに含まれる第1の技術文献群の技術文献 数との差を期待値差として算出し、

その期待値差を任意定数 ξ (但し、1 < ξ) の負の指数とした補正値 を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で 除算して類似率を算出する機能と、 前記出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する機能と、

を実現させることを特徴とする類似率算出プログラム。

22.技術文献群を入力する技術文献群入力手段と、キーワードなどの技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数とを算出して類似率を算出する類似率算出手段と、算出した類似率を出力する出力手段と、前記技術文献群入力手段と技術情報入力手段とクラスタ分解手段と類似率算出手段と出力手段とを制御をすることが可能な情報処理手段と変備えた類似率算出装置の情報処理手段にて動作し、技術文献群同士の技術的な類似性を判断するための指標を算出する類似率算出プログラムであって、

前記情報処理手段に、

20

前記技術文献群入力手段が、比較対象となる第1の技術文献群及び第-15 2の技術文献群を入力する機能と、

前記技術情報入力手段が、キーワードやIPCなどの技術情報を入力 する機能と、

前記クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に 含まれる技術文献について、前記入力した技術情報を含む技術文献を検 索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解す る機能と、

前記類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、

25 第1の技術文献群と第2の技術文献群とを混合した技術文献群の中から、第1の技術文献群の技術文献を取り出す確率に、前記クラスタ分解した混在クラスタに含まれる技術文献数を乗算して第1の技術文献群の技術文献を取り出す期待値を算出し、

前記期待値と混合クラスタに含まれる第1の技術文献群の技術文献

数との差を期待値差として算出し、

その期待値差を混在クラスタに含まれる技術文献数で除算したものを、任意定数 ξ (但し、1 < ξ) の負の指数とした補正値とし、これを 各混在クラスタについて総和を算出し、更に前記算出した全クラスタ数で除算して類似率を算出する機能と、

前記出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する機能と、

を実現させることを特徴とする類似率算出プログラム。

23.技術文献群を入力する技術文献群入力手段と、キーワードなどの 技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と を算出して類似率を算出する類似率算出手段と、算出した類似率を出力 する出力手段とを備えた類似率算出装置を用いて、技術文献群同士の技 術的な類似性を判断するための指標を算出する類似率算出方法であっ 15 て、

技術文献群入力手段が、比較対象となる第1の技術文献群及び第2の技術文献群を入力する工程と、

技術情報入力手段が、キーワードや I P-Cなどの技術情報を入力する。 工程と、

20 クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に含まれる技術文献について、前記入力した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する工程と、

類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数 25 と第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混 在クラスタ数を算出するとともに、前記クラスタ分解した結果得られた 全クラスタ数と第1の技術文献群及び第2の技術文献群の双方の技術 文献を含む混在クラスタ数との比を類似率として算出する工程と、

出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手

段に出力する工程と、

を含むことを特徴とする類似率算出方法。

24.技術文献群を入力する技術文献群入力手段と、キーワードなどの 技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にク

5 ラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と を算出して類似率を算出する類似率算出手段と、算出した類似率を出力 する出力手段とを備えた類似率算出装置を用いて、技術文献群同士の技 術的な類似性を判断するための指標を算出する類似率算出方法であって、

10 技術文献群入力手段が、比較対象となる第1の技術文献群及び第2の 技術文献群を入力する工程と、

技術情報入力手段が、キーワードやIPCなどの技術情報を入力する。 工程と、

クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に含ま 15 れる技術文献について、前記入力した技術情報を含む技術文献を検索し て、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する工 程と、

類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混 在クラスタ数を算出するとともに、各混在クラスタに含まれる技術文献 の量に応じた値を取る第1の補正値と、各混在クラスタに含まれる第1 の技術文献群の技術文献と第2の技術文献群の技術文献との混ざり具合に応じた値を取る第2の補正値とを乗算したものを各混在クラスタ について総和を算出し、前記算出した全クラスタ数で除算して類似率を 算出する工程と、

出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手 段に出力する工程と、

を含むことを特徴とする類似率算出方法。

25. 技術文献群を入力する技術文献群入力手段と、キーワードなどの

技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数とを算出して類似率を算出する類似率算出手段と、算出した類似率を出力する出力手段とを備えた類似率算出装置を用いて、技術文献群同士の技術的な類似性を判断するための指標を算出する類似率算出方法であって、

技術文献群入力手段が、比較対象となる第1の技術文献群及び第2の 技術文献群を入力する工程と、

技術情報入力手段が、キーワードや I P C などの技術情報を入力する 10 工程と、

クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に含まれる技術文献について、前記入力した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する工程と、

15 類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、個々のクラスタ内の技術文献数のα乗(但し、0 < α)に比例した補正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する工程と20、

出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する工程と、

を含むことを特徴とする類似率算出方法。

26.技術文献群を入力する技術文献群入力手段と、キーワードなどの 技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にク ラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と を算出して類似率を算出する類似率算出手段と、算出した類似率を出力 する出力手段とを備えた類似率算出装置を用いて、技術文献群同士の技 術的な類似性を判断するための指標を算出する類似率算出方法であっ て、

20

25

技術文献群入力手段が、比較対象となる第1の技術文献群及び第2の 技術文献群を入力する工程と、

技術情報入力手段が、キーワードやIPCなどの技術情報を入力する。 5 工程と、

クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に含まれる技術文献について、前記入力した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する工程と、

- 10 類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、個々のクラスタ内の技術文献数のα乗(但し、0 < α)を規格化因子で除算した補正値を各混在クラスタについて総和を算出し、類似率を算出する工程と、
- 15 出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する工程と、

を含むことを特徴とする類似率算出方法。

27. 請求の範囲26に記載の類似率算出方法において、

前記類似率算出手段が、規格化因子として、全クラスタ内の技術文献 数の平均値を用いる工程を含むことを特徴とする類似率算出方法。

2.8. 技術文献群を入力する技術文献群入力手段と、キーワードなどの技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数とを算出して類似率を算出する類似率算出手段と、算出した類似率を出力する出力手段とを備えた類似率算出装置を用いて、技術文献群同士の技術的な類似性を判断するための指標を算出する類似率算出方法であって、

技術文献群入力手段が、比較対象となる第1の技術文献群及び第2の 技術文献群を入力する工程と、

10

15

技術情報入力手段が、キーワードやIPCなどの技術情報を入力する 工程と、

クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に含まれる技術文献について、前記入力した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する工程と、

類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、前記クラスタ分解した結果得られた混在クラスタに含まれる第1の技術文献群及び第2の技術文献群の技術文献数の確率に応じて補正するために第1の技術文献群の中から加個、第2の技術文献群の中から加個の技術文献を取り出す確率のγ乗(但し、0<γ)に比例した補正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する工程と、出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する工程と、

を含むことを特徴とする類似率算出方法。

29.技術文献群を入力する技術文献群入力手段と、キーワードなどの技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数とを算出して類似率を算出する類似率算出手段と、算出した類似率を出力する出力手段とを備えた類似率算出装置を用いて、技術文献群同士の技術的な類似性を判断するための指標を算出する類似率算出方法であって、

25 技術文献群入力手段が、比較対象となる第1の技術文献群及び第2の 技術文献群を入力する工程と、

技術情報入力手段が、キーワードやIPCなどの技術情報を入力する 工程と、

クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に含ま

れる技術文献について、前記入力した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する工程と、

類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、前記クラスタ分解した結果得られた混在クラスタに含まれる第1の技術文献群及び第2の技術文献群の技術文献数の確率に応じて補正するために、第1の技術文献群の中からm、個、第2の技術文献群の中からn個の技術文献を取り出す確率の文乗(10 但し、0<γ)を規格化因子で除算した補正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する工程と、

出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手 段に出力する工程と、

15 を含むことを特徴とする類似率算出方法。

30.請求の範囲29に記載の類似率算出方法において、

前記類似率算出手段が、規格化因子として、第1の技術文献群の中から 5 m個、第2の技術文献群の中から n 個の技術文献を取り出す確率の最 大値の y 乗(但し、0 < y)を用いる工程を含むことを特徴とする類似。 率算出方法。

31.技術文献群を入力する技術文献群入力手段と、キーワードなどの技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にクラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数とを算出して類似率を算出する類似率算出手段と、算出した類似率を出力する出力手段とを備えた類似率算出装置を用いて、技術文献群同士の技術的な類似性を判断するための指標を算出する類似率算出方法であって、

技術文献群入力手段が、比較対象となる第1の技術文献群及び第2の 技術文献群を入力する工程と、 技術情報入力手段が、キーワードやIPCなどの技術情報を入力する 工程と、

クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に含まれる技術文献について、前記入力した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する工程と、

類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、第1の技術文献群に含まれる技術文献数Mと第2の技術文献群に含まれる技術文献数Nとの構成比、N/Mと、前記クラスタ分解した結果得られた混在クラスタに含まれる第1の技術文献群の技術文献数mと第2の技術文献群の技術文献数nの混在比、n/mとについて、更に構成比と混在比との比を取ったもののく乗(但し、0 < く)に比例した補正値を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で除算して類似率を算出する工程と、出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する工程と、

を含むことを特徴とする類似率算出方法。

5

10

15

32.技術文献群を入力する技術文献群入力手段と、キーワードなどの 技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にク ラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と を算出して類似率を算出する類似率算出手段と、算出した類似率を出力 する出力手段とを備えた類似率算出装置を用いて、技術文献群同士の技 術的な類似性を判断するための指標を算出する類似率算出方法であっ 25 て、

技術文献群入力手段が、比較対象となる第1の技術文献群及び第2の 技術文献群を入力する工程と、

技術情報入力手段が、キーワードやIPCなどの技術情報を入力する 工程と、 クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に含まれる技術文献について、前記入力した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する工程と、

5 類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、

第1の技術文献群と第2の技術文献群とを混合した技術文献群の中から、第1の技術文献群の技術文献を取り出す確率に、前記クラスタ分 解した混在クラスタに含まれる技術文献数を乗算して第1の技術文献群の技術文献を取り出す期待値を算出し、

期待値と混合クラスタに含まれる第1の技術文献群の技術文献数と の差を期待値差として算出し、

その期待値差を任意定数 ξ (但し、1 < ξ) の負の指数とした補正値 15 を各混在クラスタについて総和を算出し、前記算出した全クラスタ数で 除算して類似率を算出する工程と、

出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手段に出力する工程と、

を含むことを特徴とする類似率算出方法。

20 33.技術文献群を入力する技術文献群入力手段と、キーワードなどの 技術情報を入力する技術情報入力手段と、技術情報群を技術情報毎にク ラスタ分解するクラスタ分解手段と、全クラスタ数と混在クラスタ数と を算出して類似率を算出する類似率算出手段と、算出した類似率を出力 する出力手段とを備えた類似率算出装置を用いて、技術文献群同士の技 25 術的な類似性を判断するための指標を算出する類似率算出方法であっ て、

技術文献群入力手段が、比較対象となる第1の技術文献群及び第2の 技術文献群を入力する工程と、

技術情報入力手段が、キーワードやIPCなどの技術情報を入力する

工程と、

5

クラスタ分解手段が、第1の技術文献群及び第2の技術文献群に含まれる技術文献について、前記入力した技術情報を含む技術文献を検索して、該検索した技術文献をそれぞれの技術情報毎にクラスタ分解する工程と、

類似率算出手段が、前記クラスタ分解した結果得られた全クラスタ数と、第1の技術文献群及び第2の技術文献群の双方の技術文献を含む混在クラスタ数を算出するとともに、

第1の技術文献群と第2の技術文献群とを混合した技術文献群の中 10 から、第1の技術文献群の技術文献を取り出す確率に、前記クラスタ分 解した混在クラスタに含まれる技術文献数を乗算して第1の技術文献 群の技術文献を取り出す期待値を算出し、

期待値と混合クラスタに含まれる第1の技術文献群の技術文献数と の差を期待値差として算出し、

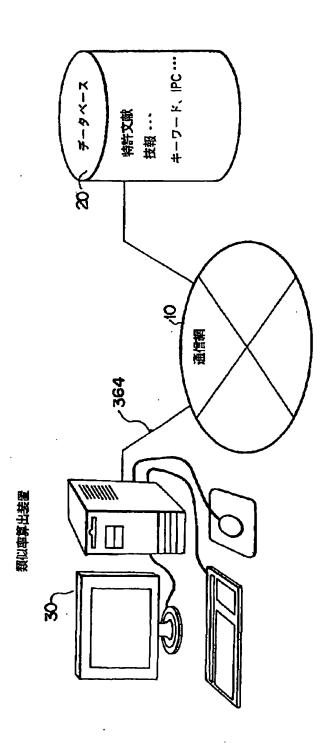
15 その期待値差を混在クラスタに含まれる技術文献数で除算したものを、任意定数 ξ (但し、1 < ξ)の負の指数とした補正値とし、これを各混在クラスタについて総和を算出し、更に前記算出した全クラスタ数で除算して類似率を算出する工程と、

出力手段が、前記算出した類似率を記録手段、表示手段、又は通信手 20 段に出力する工程と、

を含むことを特徴とする類似率算出方法。

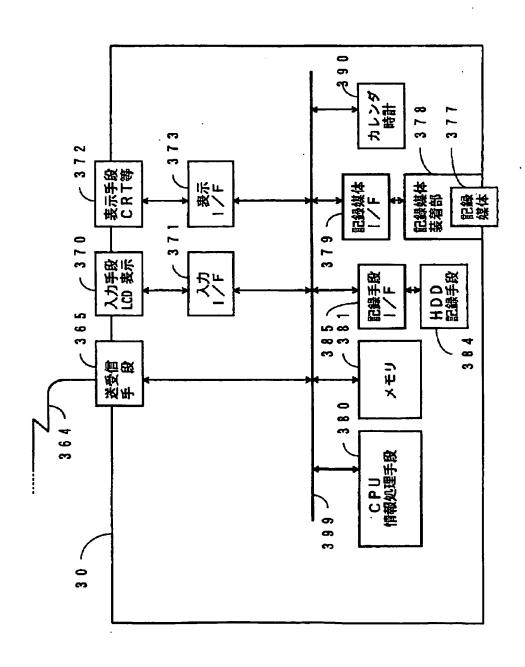
1/19

第1図



2/19

第2図



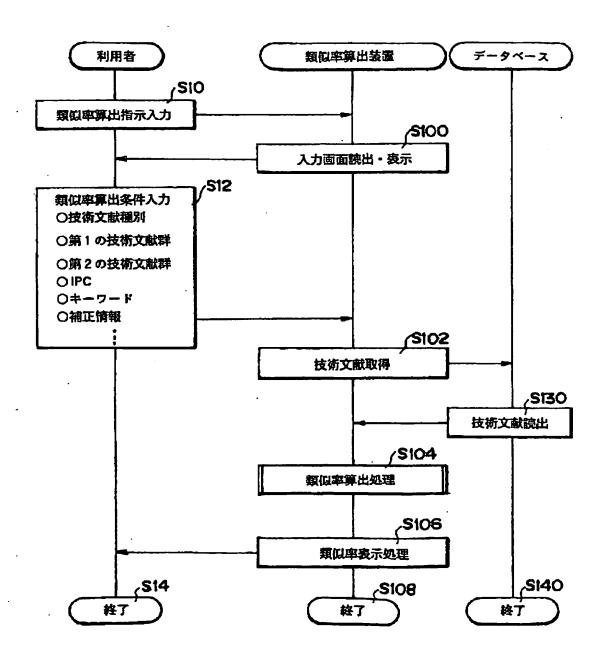
3/19

第3図

第1の技術文献群(A群) A1,A2,A3,,,AM 第2の技術文献群 (B群) B1,B2,B3,,,,BN

4/19

第 4 図



5/19

## 第5図

	—— 入力画面		
1.クラスタ分解の条件入力			
(1) 対象文書	(2) 対象部分	(3)	クラスタ分解の尺度
1.特許公報 2.技術文献 : : : : : : : : : : : : : :	1.全文 2.請求項部分のみ		.IPC
2.技術文献群の抽出条件			
第1の技術文献群		第2の	技術文献群
(1) 期間		(1) 期間	
◎日付指定 03/06/13 ▼	3/09/11 ¥	〇日付指定	03/09/11 v - v
○過去		● 過去	6 🖢 か月間
〇過去 一 日間		〇過去	一 日間
(2) 集界 下からお選び下 1.通信 2.家理 3.金融 4. i	さい	(2) 業界	下からお選び下さい ▼ 1.通信 2.家電 3.金融 4. i
(3) 企業名 下からお遠び下 個人名 1.0000株式 2.△△△△株式 3. 1 4. 1	会社	(3) 企業名 個人名	下からお選び下さい ▼ 1.0000株式会社 2.△△△△株式会社 3. i 4.
3. 補正方法 補正項 1 2.技術文献数量 1.なし 2.技術文献数量 3. 4.		1.なし 2.技術文 3.技術文	献の期待値差 財数の確立 財の退在比 財の期待値差

6/19

## 第6図

	-	——類似	率表示画	面——			
1.クラスタ分解の3	条件 [	1.特許公報	2.技術文制	7.キーワー	ド「電話」・	••	
2.技術文献群の抽出	_					·	
第1の技術文							
•••	期間	03/0	6/13~03	/09/11			
	樂界	1.通信					
	企業名	1.0000	)株式会社				
	その他						
第2の技術文献群	ł						
(1)	期間	03/06	/13~03/	12/13			
	業界	2.家電					
	企業名	2.ΔΔ2	全大科公2	<u> </u>			
(4)	その他						
3.補正方法の条件	ĺ	補正項1	= 2 補正4	2 = 4 補正	項3 = 0.30	00	
4.類似率の算出結 5.分解したクラス:		類似	率	0.93	35		
3.分辨したグラへ。	y0   1 <del>111</del>		クラスタ1	クラスタ2	•••	• • •	
		尺度	「G06F 17/30」	「テキスト 処理」		•••	
		補正項1	3,774	0.075			
		補正項2	0.971	0.971			i
		補正項3	1.000	1,000			
	件 a Y		<b>?</b> 3	<u>4 5 </u>	\$ <b>?</b>	\$ 9 1 -	b b
	Ε		- 				_

7/19

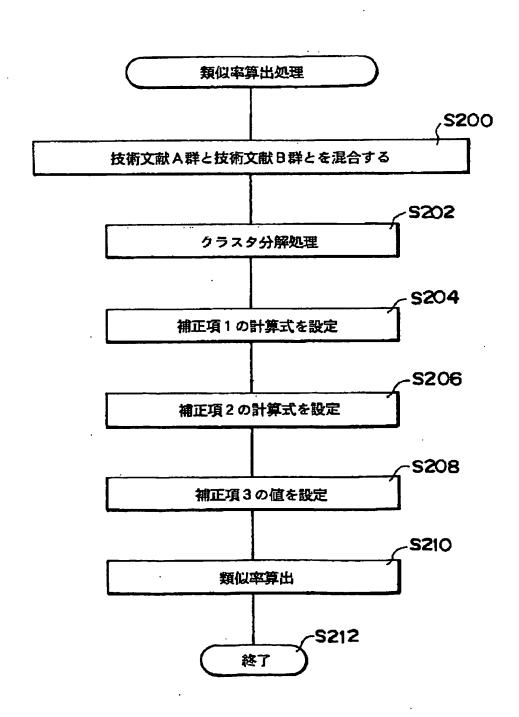
第7図

A1,B1 A2,B2,B3 A3 B1 · · · · A100, AM, B13 BN 「G06F17/30」「テキスト処理」「B01」「無機化合物」

PCT/JP2004/004451

8/19

第8図



9/19

# 第9図

第2の 技術文 献群 も	<b>技</b>	•	<b>クラスタ1</b>		. 1	1978	8	カラスタ 8	1574 4	数待する図串値
故 計		技術 文献 数 m 1	技術 大概 東京 東京	女 女 敬 击	技術 文献 数 数 M2	按 被 数 27	按 女 存 計	技術文歌 撥 四3	技術文件 数 104	許容範囲 ±0.050
12 2			1	3	2	1	3	2	4	0.300
169 10		100	50	150	2	1	3	2	4	0.900
159 2		20	99	70	2	1	3	82	4	0.200
169		2	20	52	20	1	21	82	4	0.050

10/19

第10図

A1,A2,A7,A8,A10,A15,A18 · · · A120,Am-1

B4,B5,B7,B15,B17,B18 · · · B150,Bn-10

クラスタ 1

A3,A4 B1 A10



クラスタ2 クラスタ3 クラスタ4

11/19

第11図

	路切壁	(4) th		0.6	0.962	0.459	0.459
《率算出例	クラスタ2	地下版 1 MM	1010年	1	0.075	0.075	0.528
)による類似	17.	技術文献数	(m2+n2)	က	တ	က	. 21
a=1、補正項2=1、補正項3=1の場合の(式4)による類似率算出例	クラスタ1	44 0 × 10 × 10 × 10 × 10 × 10 × 10 × 10	毎月女 1 9 節	1	3.774	1.761	1.308
<b>氰正項 3 = 1 0</b>	13.	技術文献數	(m14n1)	က	150	20	62
5項2=1、#		(N+N)/4		12/4	159/4	159/4	159/4
$\alpha = 1$ , $\mathbf{m}$	1	数数数数数数数数数数数数数数数数数数数数数数数数数数数数数数数数数数数数数数数	が無い	条件1	条件2	<b>条件3</b>	条件4
				—	1		

12/19

第12図

y=1.	、補正項1=	- 1、補正項3	y=1、補正項1=1、補正項3=1の物合の(式10)による類以率単日例	(天10) 行	よる類似率事	田利	
į		クラスタ1			クラスタ2		a (J) eak
数 2 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4	4	混在確率	補正項2	42 442 44 EX	湿在確密	相正項2	* * * * * * * * * * * * * * * * * * *
計算	既任備率	の最大値	(1)の値	插件备件	の最大値	(1)の値	4
条件1	0.409	0.409	T	0.409	0.409	1	0.5
条件2	0.113	0.280	0.404	0.448	0.448	1	0.35
条件3	0.000	0.133	0.000	0.448	0.448	1	0.25
各件 4	0000	0.141	0.000	0.001	0.194	0.004	0.00

13/19

第13図

補正項 2(1) 補圧項 1× 0.0005 0.019 整四番 0.4 0.5 ×補正項 2(1) 補正項1 0.075 0.075 0.003 クラスタ2 2(1)の億 補后項 0.004 楠正項1(1)及び補正項2(1)を採用した場合の類似率算出例 補正項 1 0.075 0.075 0.528 の運 梅尼斯 1×柏 正項 2(1) 1.525 0.000 0.000 クラスタ1 2(1)の値 0.404 0.000 補正項 0.000 補正項1 8.774 1.308 1.761 の鶴 条件2 条件8 条件4 条件1 類気争 計算例

14/19

第14図

C=1、補正項1=1、補正項3=1の場合の(式26)による類似率算出例 類似率       カラスタ1       カラスタ3         類似率 計算例       N/M       n1/m1       相正項2       n2/m2       相正項2         条件1       1       0.5       0.5       0.5       0.5       0.5         条件2       0.529       0.5       0.945       0.5       0.945       0.945         条件3       0.529       2.5       0.0212       0.05       0.945         条件3       0.529       2.5       0.021       0.05       0.095

15/19

第15図

na.	×	<u>a</u>			l	
類似率	<b>福田風1×</b>	桶正項 2(2)	0.25	0.909	0.111	0.019
	桶正項 1×	補正項 2(2)	0.5	0.071	0.071	0.050
クラスタ2	模正項	2(2)の値	0.5	0.945	0.945	960'0
	補正項1	9 額	П	0.075	0.075	0.528
	梅尼項 1×楠	正項 2(2)	0.5	3.566	0.878	0.027
クラスサ	補币項	2(2)の値	0.5	0.946	0.212	0.021
	補正項1	の値	1	8.774	1.761	1.308
類似率	計算例		条件1	条件2	条件3	条件4
	クラスタ1 クラスタ2	カラスタ1         クラスタ2           補正項1         補正項1×箱         補正項1         補正項1×	神正項1         補正項 (21)の値         加工項 (21)の値         加工項 (21)の値         相正項 (21)         相正項 (21)         相正項 (21)	a         クラスタ1         力ラスタ2           補正項1         補正項1         補正項1×補         補正項1×         補正項1×         相正項1×           の値         2(2)の値         相正項2(2)         の値         2(2)の値         補正項2(2)           1         0.5         0.5         1         0.5         0.5	自       クラスタ1       クラスタ1       有圧項1       有圧項1       有圧項1×         前       有圧項1       有圧項1×       有圧項1×       有圧項1×         0       2(3)の値       正項2(2)       の値       2(2)の値       有圧項1×         1       0.5       0.5       1       0.5       0.5         2       8.774       0.945       3.566       0.075       0.945       0.071	a         カラスタ1         カラスタ2           a         相正項1         補正項1×補         補正項1         補正項1×         補正項1×           の値         2(2)の値         正項2(2)         の値         2(2)の値         補正項1×           1         1         0.5         0.5         1         0.5           2         8.774         0.946         3.566         0.075         0.945         0.071           3         1.761         0.212         0.373         0.075         0.945         0.071

16/19

第16図

(式31) に条件1~4を代入した場合の期待値差の算出例

	期待值差	0.5	0.038	0.038	6.264
クラスタ2	$m2\times N$	12	110	110	1,100
	$n2\times M$	9	104	104	104
	期待值差	0.5	1.887	25.786	32.013
がです。 初待値差 クラスタ1	m1×N	12	6,500	1,100	110
	$n1\times M$	9	5,200	5,200	5,200
期待值差	算出例	条件1	条件2	条件3	条件4
	期待値差 クラスタ1 クラスタ2	クラスタ1       n1×M     加1×N     期待値差     n2×M	クラスタ1       クラスタ2         n1×M       加1×N       期待値差       n2×M       m2×N         6       12       0.5       6       12	カラスタ1       カラスタ1         n1×M       m1×N       期待値差       n2×M       m2×N         6       12       0.5       6       12         5,200       5,500       1.887       104       110	カラスタ1       カラスタ1         n1×M       m1×N       期待値差       n2×M       m2×N         6       12       0.5       6       12         5,200       5,500       1.887       104       110         5,200       1,100       25.786       104       110

17/19

第17図

F O	1片切1-1、	5=10、無片型1=1、無片型3=1の部内の(大37)にその数で中本日か	20年)(70年)	こころの数弦型	LATIA:
-	クラ	クラスタ1	クラン	クラスタ2	#1 (C) 58
	A CAN	補正項 2(3)	**************************************	補正項 2(8)	+ 1 (A)
	この記載	の値	ない。	の値	(0.0xx)
Π	0.167	0.681	0.167	0.681	0.340
条件2	0.013	0.971	0.013	0.971	0.485
条件3	0.368	0.429	0.013	0.979	0.350
条件4	0.616	0.242	0.298	0.504	0.187

18/19

第18図

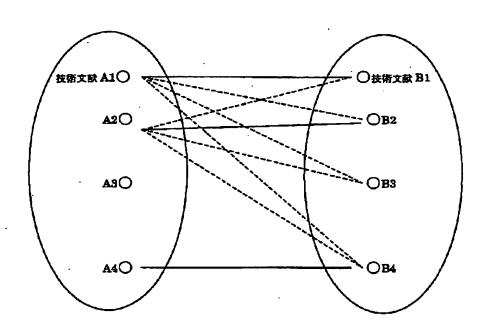
補正項1 (1)及び補正項2 (3)を採用した場合の類似率算出例

	1 1 1 1 1	ころしまっと	日子では、「こくなり 四十人」(こ) いただい こうしょう しょうしょう	L AMP III				
整区岛		クラスタ1	1		17742	2	類②舉	
計算例	1	相正項	梅正頃 1×補	4	権正項	植正項1×植	補正項1	
	· 電片項 I	2(3)	正項 2(3)	無 元 女 1 ·	2(8)	正項 2(3)	×補正項 2(3)	
条件1	7	0.681	0.681	1	0.681	0.681	0.340	
条件2	3.774	0.971	3.665	0.075	126.0	0.073	0.935	
条件3	1.761	0.429	0.755	0.075	0.971	0.073	0.207	
条件4	1.308	0.242	0.317	0.528	0.504	0.266	0.146	

PCT/JP2004/004451

19/19

第19図



#### INTERNATIONAL SEARCH REPORT

International application No.

		PC1/JP	2004/004451	
A. CLASSIFIC Int.Cl <sup>7</sup>	ATION OF SUBJECT MATTER G06F17/30			
According to Inte	ernational Patent Classification (IPC) or to both national	l classification and IPC	•	
B. FIELDS SE	ARCHED			
	entation searched (classification system followed by cla G06F17/30	assification symbols)		
	·			
Jitsuyo		nt that such documents are included in th kai Jitsuyo Shinan Koho tsuyo Shinan Toroku Koho	ne fields searched 1971–2004 1996–2004	
	ase consulted during the international search (name of c FILE (JOIS), WPI, INSPEC (DIALOG)	lata base and, where practicable, search	erms used)	
C. DOCUMEN	TS CONSIDERED TO BE RELEVANT			
Category*	Citation of document, with indication, where ap	propriate, of the relevant passages	Relevant to claim No.	
A	Kimio ARAI, "Tokkyo Joho Buns Map", The Journal of Informat Technology Association, 01 Ja 01.03), Vol.53, No.1, pages 1 all drawings	ion Science and nuary, 2003 (01.	1-33	
	<u> </u>		<u> </u>	
	cuments are listed in the continuation of Box C.	See patent family annex.		
"A" document de to be of part	gories of cited documents: efining the general state of the art which is not considered icular relevance	"T" later document published after the in date and not in conflict with the appli the principle or theory underlying the	cation but cited to understand	
"E" earlier applie filing date	cation or patent but published on or after the international	"X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive		
cited to esta	thich may throw doubts on priority claim(s) or which is ablish the publication date of another citation or other	step when the document is taken alor "Y" document of particular relevance; the		
"O" document re	on (as specified) ferring to an oral disclosure, use, exhibition or other means	considered to involve an inventive combined with one or more other successions.	h documents, such combination	
"P" document pu the priority of	ublished prior to the international filing date but later than date claimed	being obvious to a person skilled in t  "&" document member of the same paten		
	completion of the international search	Date of mailing of the international sea		
28 June	2, 2004 (28.06.04)	13 July, 2004 (13.	07.04)	
	g address of the ISA/	Authorized officer		
oapanes	se Patent Office			
Facsimile No.		Telephone No.		

Form PCT/ISA/210 (second sheet) (January 2004)

A. 発明の属	はする分野の分類 (国際特許分類 (IPC))		
Ιn	t.Cl'G06F17/30		
B. 調査を行	でのた公野		
	けったガット か、限資料(国際特許分類(IPC))		
In	t.Cl'G06F17/30		
	トの資料で調査を行った分野に含まれるもの		
日本国実用		•	
	実用新案公報 1994-200 実用新案公報 1971-200		
	新案登録公報 1996-200		
国際調査で使用	月した電子データベース (データベースの名称、	調査に使用した用語)	
JICS	Tファイル (JOIS), WPI, INSPEC	C (DIALOG)	
C. 関連する			
引用文献の			関連する
カテゴリー*	引用文献名 及び一部の箇所が関連すると	きは、その関連する箇所の表示	請求の範囲の番号
Α	新井喜美雄,特許情報分析とパテント 2003.1.1,第53巻,第1号 図	-	1-33
□ C欄の続き	きにも文献が列挙されている。 	□ パテントファミリーに関する別	紙を参照。
もの 「E」国際出 以後に 「L」優先権 日若し 文献(J 「O」口頭に	のカテゴリー 車のある文献ではなく、一般的技術水準を示す 類日前の出願または特許であるが、国際出願日 公表されたもの 主張に疑義を提起する文献又は他の文献の発行 くは他の特別な理由を確立するために引用する 理由を付す) よる開示、使用、展示等に言及する文献 願日前で、かつ優先権の主張の基礎となる出願	の日の後に公表された文献 「T」国際出願日又は優先日後に公表出願と矛盾するものではなく、の理解のために引用するもの 「X」特に関連のある文献であって、の新規性又は進歩性がないと考 「Y」特に関連のある文献であって、上の文献との、当業者にとってよって進歩性がないと考えられ 「&」同一パテントファミリー文献	発明の原理又は理論 当該文献のみで発明 えられるもの 当該文献と他の1以 自明である組合せに
国際調査を完	了した日 28.06.2004	国際調査報告の発送日 13.7.	2004
日本	の名称及びあて先 国特許庁(ISA/JP) 郵便番号100-8915 都千代田区霞が関三丁目4番3号	特許庁審査官 (権限のある職員) 深津 始 電話番号 03-3581-1101	5M 9383 内線 3597

# This Page is Inserted by IFW Indexing and Scanning Operations and is not part of the Official Record

### **BEST AVAILABLE IMAGES**

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images include but are not limited to the items checked:

BLACK BORDERS

IMAGE CUT OFF AT TOP, BOTTOM OR SIDES

FADED TEXT OR DRAWING

BLURRED OR ILLEGIBLE TEXT OR DRAWING

SKEWED/SLANTED IMAGES

COLOR OR BLACK AND WHITE PHOTOGRAPHS

GRAY SCALE DOCUMENTS

LINES OR MARKS ON ORIGINAL DOCUMENT

REFERENCE(S) OR EXHIBIT(S) SUBMITTED ARE POOR QUALITY

## IMAGES ARE BEST AVAILABLE COPY.

OTHER:

As rescanning these documents will not correct the image problems checked, please do not report these problems to the IFW Image Problem Mailbox.